

UNIVERSIDADE FEDERAL DO PARANÁ

LUCAS DA SILVA RIBEIRO

ANÁLISE E PREDIÇÃO DAS DEFORMAÇÕES DO CONCRETO EM DADOS DE
INSTRUMENTAÇÃO UTILIZANDO UM MÉTODO HÍBRIDO

CURITIBA

2019

LUCAS DA SILVA RIBEIRO

ANÁLISE E PREDIÇÃO DAS DEFORMAÇÕES DO CONCRETO EM DADOS DE
INSTRUMENTAÇÃO UTILIZANDO UM MÉTODO HÍBRIDO

Tese apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia na área de concentração de Programação Matemática, dos setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial à obtenção do título de doutor.

Orientador: prof. Dr. Volmir Eugênio Wilhelm

Coorientador: Eng. Dr. Étore Funchal de Faria

Coorientador: prof. Dr. Jairo Marlon Corrêa

CURITIBA

2019

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

R484a

Ribeiro, Lucas da Silva

Análise e predição das deformações do concreto em dados de instrumentação utilizando um método híbrido [recurso eletrônico] / Lucas da Silva Ribeiro. – Curitiba, 2019.

Tese - Universidade Federal do Paraná, Setor de Tecnologia e de Ciências Exatas, Programa de Pós-Graduação em Métodos Numéricos em Engenharia na área de concentração de Programação Matemática, 2019.

Orientador: Volmir Eugênio Wilhelm. Coorientador: Étore Funchal de Faria. Coorientador: Jairo Marlon Corrêa

1. Análise de series temporais. 2. Redes neurais (Computação). 3. Concreto - Efeito da temperatura. I. Universidade Federal do Paraná. II. Wilhelm, Volmir Eugênio. III. Faria, Étore Funchal de. IV. Corrêa, Jairo Marlon. V. Título.

CDD: 620.136

Bibliotecária: Vanusa Maciel CRB- 9/1928



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA E SETOR DE CIÊNCIAS EXATAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO MÉTODOS NUMÉRICOS
EM ENGENHARIA

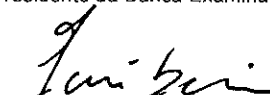
TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de doutorado de **LUCAS DA SILVA RIBEIRO** intitulada: **ANÁLISE E PREDIÇÃO DAS DEFORMAÇÕES DO CONCRETO EM DADOS DE INSTRUMENTAÇÃO UTILIZANDO UM MÉTODO HÍBRIDO**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

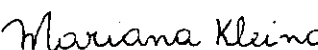
CURITIBA, 08 de Julho de 2019.


ÉTORE FUNCHAL DE FARIA
Presidente da Banca Examinadora


EDUARDO DE MORAES REGO FAIRBAIRN
Avaliador Externo (UFRJ)


LUIZ ALKIMIN DE LACERDA
Avaliador Interno (UFPR)


ANA CAROLINA PARAPINSKI DOS SANTOS
Avaliador Externo (UNILA)


MARIANA KLEINA
Avaliador Interno (UFPR)

Dedico este trabalho ao trino Deus
Pai, Filho e Espírito Santo. Autor da
vida e da minha salvação.

À minha amada esposa Samara,
minha eterna namorada e
companheira de todas as horas.

Às minhas filhas Ana Laura e
Cristina, heranças de Deus em
minha vida.

AGRADECIMENTOS

Primeiramente ao meu Senhor e Salvador Jesus Cristo! Autor da Vida e da minha salvação. Obrigado pela saúde, inteligência e fé para seguir em frente em todos os momentos!!!

Ao professor Dr. Volmir Eugênio Wilhelm, por aceitar o desafio de me orientar neste trabalho, sempre acessível e disponível dando-me o devido direcionamento e incentivo para o bom êxito no desenvolvimento desta tese.

Aos meus co-orientadores Eng. Dr. Étore Funchal de Faria (da Itaipu) e Prof. Dr. Jairo Marlon Corrêa (da UTFPR) pelo precioso auxílio em cada solicitação que fiz, além de amigos e parceiros de pesquisa.

À minha preciosa família: Samara Rejane N. P. Ribeiro minha esposa que sempre foi suporte para mim, incentivando e com muitas renúncias pessoais para que eu pudesse concluir com sucesso esta tese de doutorado e minhas filhas Ana Laura e Cristina (que nasceu milagrosamente durante o doutorado) que sempre me esperavam em casa com muita saudade... Vocês são as mulheres da minha vida!!!

Aos meus pais Pedro Flores Ribeiro (in memória) e Olinda da Silva Ribeiro que me ensinaram valores preciosos que marcaram minha vida como respeito, trabalho, honestidade e amor a família. Aos meus irmãos: Suzana, Adriana, Laércio e Adriana que mesmo longe fisicamente sempre me incentivaram e me sustentaram com suas orações.

Aos meus sogros: Luiz Carlos Polidoro Persigo e Loreni Miriam Nunes Persigo que não mediam esforços para nos ajudar em meio a correria de estudos, pesquisa e viagens.

Aos meus colegas de departamento, Diego e Samuel que com questionamentos e sugestões, me ajudaram muito mesmo. Obrigado amigos!!!

À usina hidrelétrica de Itaipu pelo fornecimento dos dados experimentais para o desenvolvimento desta pesquisa.

E a todos os demais colegas de departamento de Matemática e Estatística – DAMAT da UTFPR campus Medianeira, que de uma forma ou de outra me incentivavam, cobravam e me encorajavam a sempre seguir em frente... obrigado a todos vocês!!!

“Todos os modelos estão errados, alguns são úteis.”
(George E. P. Box, 1976)

RESUMO

Este estudo apresenta um método híbrido, denominado SARIMAX-NEURAL, aplicado a séries temporais sazonais univariadas. O método proposto representa uma combinação linear dos modelos autorregressivos integrado de médias móveis (metodologia Box & Jenkins), como modelo de predição das deformações corrigidas do concreto influenciadas pela temperatura ambiente, e de redes neurais artificiais como modelo de predição dos resíduos obtidos da modelagem Box & Jenkins. Trata-se de uma metodologia estatística para predição de séries temporais com estrutura de auto dependência linear dos dados e que é aplicada em diversas áreas da ciência. As redes neurais artificiais são eficientes para modelagem de predição de séries temporais com estrutura de auto dependência não linear nos dados. O método híbrido SARIMAX-NEURAL foi proposto nesta tese como combinação linear ou soma dos modelos Box & Jenkins e dos modelos de redes neurais *Deep Learning* com arquitetura Long Short-Term Memory, que representa a modelagem de predição de séries temporais sazonais univariadas com estrutura de dependência linear e não linear. As séries temporais das deformações corrigidas do concreto foram obtidas a partir de dados históricos medidos por rosetas de deformímetro instaladas em um bloco de contraforte da barragem da usina hidrelétrica de Itaipu. O método híbrido proposto, que considerou o efeito da temperatura ambiente sobre as deformações do concreto, apresentou resultados eficientes na comparação com os métodos individuais em que não foi considerado o efeito da temperatura ambiente. Os ganhos de precisão preditiva ficaram entre 29% e 37%.

Palavras-chave: Séries temporais. Redes neurais Deep Learning. Modelos Box & Jenkins.

ABSTRACT

This study presents a hybrid method, called SARIMAX-NEURAL, applied to univariate seasonal time series. The proposed method is a linear combination of autoregressive integrated moving average models (Box & Jenkins methodology) as predict the corrected concrete deformation influenced by ambient temperature model, and artificial neural networks as prediction model of the residuals obtained from Box & Jenkins modeling. This is a statistical methodology for the prediction of time series with a linear self-dependency structure of the data and that is applied in several areas of science. Artificial neural networks are efficient for modeling prediction of time series with nonlinear dependence structure in the data. The hybrid method SARIMAX-NEURAL was proposed in this thesis as a linear combination or sum of the Box & Jenkins models and the Deep Learning neural network models with Long Short-Term Memory architecture, which represents the prediction modeling of univariate seasonal time series with linear dependence structure and non-linear. The time series of the corrected deformation of concrete were obtained from historical data measured by rosettes strains installed on a dam buttress block the hydroelectric plant of Itaipu. The proposed hybrid method, which considered the effect of the ambient temperature on the deformations of the concrete, presented efficient results in comparison with the individual methods in which the effect of the ambient temperature was not considered. Predictive accuracy gains were between 29% and 37%.

Key-words: Times series. Artificial neural networks RBF. Box & Jenkins models.

LISTA DE FIGURAS

FIGURA 1 - REVERSIBILIDADE DA FLUÊNCIA.....	27
FIGURA 2 - REVERSIBILIDADE DA RETRAÇÃO.....	28
FIGURA 3 - RELAÇÃO ENTRE A FRAÇÃO VOLUMÉTRICA DO CONCRETO E A RETRAÇÃO DO CONCRETO.....	28
FIGURA 4 - EXCESSO DE DEFORMAÇÃO PRODUZIDA POR SECAGEM (EFEITO PICKETT).....	29
FIGURA 5 - DEFORMAÇÃO DEPENDENTE DO TEMPO EM CONCRETO SUBMETIDO A CARGA CONSTANTE.....	30
FIGURA 6 - ROSETA DE DEFORMÍMETRO.....	34
FIGURA 7 - REPRESENTAÇÃO DE UM DEFORMÍMETRO.....	35
FIGURA 8 - BALDE A TENSORIAL E MAIS AO FUNDO UMA ROSETA DE DEFORMÍMETRO.....	36
FIGURA 9 - ROSETAS DE DEFORMÍMETRO INSTALADAS EM UM BLOCO DE CONTRAFORTE.....	36
FIGURA 10 - FLUXOGRAMA DO MODELO SARIMAX.....	45
FIGURA 11 - DECOMPOSIÇÃO DE UMA SÉRIE TEMPORAL E AS COMPONENTES DE TENDÊNCIA, SAZONALIDADE E COMPONENTE ALEATÓRIA.....	50
FIGURA 12 - REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO HUMANO E UMA REDE NEURAL CORRESPONDENTE.....	51
FIGURA 13 - ARQUITETURA LSTM DE UMA REDE DEEP LEARNING.....	55
FIGURA 14 - FLUXOGRAMA DO MÉTODO HÍBRIDO SARIMAX-NEURAL.....	65
FIGURA 15 - FLUXOGRAMA DA MODELAGEM SARIMAX.....	68
FIGURA 16 - PRINCIPAIS PARÂMETROS UTILIZADOS NO TREINAMENTO DA REDE NEURAL RECORRENTE DEEP LEARNING COM ARQUITETURA LSTM ..	71
FIGURA 17 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D09-D57	72
FIGURA 18 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D09.....	73
FIGURA 19 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D09 DO BLOCO DE CONTRAFORTE D57 E DA TEMPERATURA AMBIENTE	74

FIGURA 20 – DADOS DE DEFORMAÇÕES E PREDIÇÕES DA SÉRIE TEMPORAL RD-D09-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL	77
FIGURA 21 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D09-5-D57	78
FIGURA 22 – DADOS E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D09 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL.....	80
FIGURA 23 - PROJEÇÃO DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D09-5	81
FIGURA 24 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORESPONDENTE A ROSETA RD-D010-D57	82
FIGURA 25 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D010-D57	83
FIGURA 26 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D010.....	84
FIGURA 27 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D010 E DA TEMPERATURA AMBIENTE	85
FIGURA 28 – DADOS DE DEFORMAÇÕES, INTERVALO DE PREDIÇÃO E AS PREDIÇÕES DA SÉRIE TEMPORAL RD-D010-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL	87
FIGURA 29 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D010-5-D57	88
FIGURA 30 – DADOS E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D010 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL ..	90
FIGURA 31 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D010-5	91
FIGURA 32 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORESPONDENTE A ROSETA RD-D011-D57	92
FIGURA 33 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D011-D57	93
FIGURA 34 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D011.....	94

FIGURA 35 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D011 E DA TEMPERATURA AMBIENTE	95
FIGURA 36 – DADOS DE DEFORMAÇÕES E AS PREDIÇÕES DA SÉRIE TEMPORAL RD-D011-1 E RD-D011-2 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL.....	97
FIGURA 37 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D011-1 E RD-D011-2	98
FIGURA 38 – DADOS DE DEFORMAÇÕES E PREDIÇÕES DE TRÊS BRAÇOS DA ROSETA RD-D011 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL	101
FIGURA 39 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D011-1 E RD-D011-2	102
FIGURA 40 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D012-D57	103
FIGURA 41 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D012-D57	103
FIGURA 42 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D012.....	104
FIGURA 43 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D012 E DA TEMPERATURA AMBIENTE	105
FIGURA 44 – DADOS DE DEFORMAÇÕES, INTERVALOS DE PREDIÇÕES E AS PREDIÇÕES DAS SÉRIES TEMPORAIS RD-D012-1 E RD-D012-2 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL.....	107
FIGURA 45 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D012-1 E RD-D012-2	108
FIGURA 46 – DADOS E PREDIÇÕES DE TRÊS BRAÇOS DA ROSETA RD-D012 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL.....	111
FIGURA 47 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D012-1 E RD-D012-2	112

FIGURA 48 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D013-D57	113
FIGURA 49 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D013-D57	114
FIGURA 50 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D013.....	115
FIGURA 51 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D013 E DA TEMPERATURA AMBIENTE	116
FIGURA 52 – DADOS DE DEFORMAÇÕES E AS PREDIÇÕES COM O INTERVALO DE CONFIANÇA DA SÉRIE TEMPORAL RD-D013-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL.....	118
FIGURA 53 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D013-5.....	119
FIGURA 54 – DADOS DE DEFORMAÇÃO E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D013 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL	121
FIGURA 55 – DADOS, PREDIÇÕES E PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D013-5	122
FIGURA 56 - COMPARAÇÃO DOS VALORES MÉDIOS DAS ESTATÍSTICAS MAE, MAPE E RMSE PARA AS 25 SÉRIES TEMPORAIS DAS 5 ROSETAS DO BLOCO D57.....	124
FIGURA 57 - CURVAS DE DEFORMAÇÕES.....	157
FIGURA 58 - VARIAÇÃO DE $\beta_f(t)$ EM RELAÇÃO À IDADE FICTÍCIA DO CONCRETO.....	159
FIGURA 59 - VARIAÇÃO DE $\beta_s(t)$ EM RELAÇÃO AO TEMPO, EM DIAS.....	161

LISTA DE TABELAS

Tabela 1 - FATORES QUE INFLUENCIAM NA FLUÊNCIA DO CONCRETO AO LONGO DO TEMPO	31
TABELA 2 - PARÂMETROS DE ENTRADA DOS MODELOS DE FLUÊNCIA (F*) E RETRAÇÃO (R*)	32
TABELA 3 - LIMITAÇÃO DOS MODELOS DE FLUÊNCIA E RETRAÇÃO	33
TABELA 4 - PERFIL GRÁFICO DA FAC E DA FACP PARA MODELOS DE SÉRIES TEMPORAIS ESTACIONÁRIAS DA METODOLOGIA BOX & JENKINS	42
TABELA 5 - COMPARAÇÃO DE ESTRUTURAS ENTRE AS REDES NEURAIS MLP E RBF	53
TABELA 6 – CORRELAÇÕES LINEARES DEFASADAS DAS DEFORMAÇÕES DO CONCRETO COM A TEMPERATURA AMBIENTE DE TODAS AS ROSETAS DE DEFORMÍMETRO DO BLOCO DE CONTRA FORTE D57	71
TABELA 7 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D09	75
TABELA 8 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MODELOS PREDITIVOS DA ROSETA RD-D09-D57	75
TABELA 9 - COMPARAÇÃO DAS ESTATÍSTICAS DE ADERÊNCIA DAS PREDIÇÕES DA ROSETA RD-D09-5	78
TABELA 10 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D09-5 ..	79
TABELA 11 - COMAPARAÇÃO DA PRECISÃO DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA A ROSETA RD-D09	79
TABELA 12 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D010	85
TABELA 13 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D010-D57	86
TABELA 14 - COMPARAÇÃO DE ACURÁCIAS DAS PREDIÇÕES DO BRAÇO CINCO DA ROSETA RD-D010	89
TABELA 15 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D010-589	

TABELA 16 - COMAPARAÇÃO DAS MÉDIAS DOS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA 4 BRAÇOS DA ROSETA RD-D010	90
TABELA 17 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D011	96
TABELA 18 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MODELOS PREDITIVOS DA ROSETA RD-D011-D57	96
TABELA 19 - COMPARAÇÃO DOS ERROS DAS PREDIÇÕES DOS BRAÇOS UM E DOIS DA ROSETA RD-D011.....	99
TABELA 20 - COMPARAÇÃO DOS PERCENTUAIS PREDITIVOS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS EM DOIS BRAÇOS DA ROSETA RD-D011.....	99
TABELA 21 - COMAPARAÇÃO OS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 3, 4 E 5 DA ROSETA RD-D011	100
TABELA 22 - TESTES ADF E KPSS PARA VERIFICARA A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D012	106
TABELA 23 - ESTATÍSTIAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D012-D57	106
TABELA 24 - COMPARAÇÃO DAS ESTATÍSTIAS DE ADERÊNCIA DAS PREDIÇÕES DOS BRAÇOS UM E DOIS DA ROSETA RD-D012	109
TABELA 25 - COMPARAÇÃO DA PRECISÃO PERCENTUAL PREDITIVA DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS EM DOIS BRAÇOS DA ROSETA RD-D012.....	109
TABELA 26 - COMAPARAÇÃO DOS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 3, 4 E 5 DA ROSETA RD-D012	110
TABELA 27 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D012	116
TABELA 28 - ESTATÍSTIAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D013-D57	117
TABELA 29 - COMPARAÇÃO DA PRECISÃO DAS PREDIÇÕES DA ROSETA RD-D013-5 EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS	119

TABELA 30 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D013-5	120
TABELA 31 - COMAPARAÇÃO DAS ACURÁCIAS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 1, 2, 3 E 4 DA ROSETA RD-D013.....	120
TABELA 32 - COMPARAÇÃO DO GANHO PREDITIVO MÉDIO EM PORCENTAGEM DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS.....	123
TABELA 33 - COMPARAÇÃO DA PRECISÃO DAS ESTATÍSTICAS DE ADERÊNCIA MAE, MAPE E RMSE DOS MÉTODOS PREDITIVOS DAS 25 SÉRIES TEMPORAIS MODELADAS DO BLOCO D57	123
TABELA 34 - VALORES DE REFERÊNCIA DOS COEFICIENTES k_s E k_h	145
TABELA 35 - VALORES DE REFERÊNCIA PARA OS COEFICIENTES α_{ds1} e α_{ds2}	149
TABELA 36 - VALORES DE k_h NA EQUAÇÃO (78)	149
TABELA 37 - FATOR DE CORREÇÃO REFERENTE AO PERÍODO DE CURA INICIAL ÚMIDA	153
TABELA 38 - VALORES USUAIS PARA DETERMINAÇÃO DA FLUÊNCIA E DA RETRAÇÃO	158
TABELA 39 - VALORES DA FLUÊNCIA E DA RETRAÇÃO POR SECAGEM EM FUNÇÃO DA VELOCIDADE DO ENDURECIMENTO DO CONCRETO	162
TABELA 40 - VALORES CARACTERÍSTICOS DA DEFORMAÇÃO ESPECÍFICA $\varepsilon_{\infty}(\infty, t_0)$ E O COEFICIENTE DE FLUÊNCIA $\varphi(\infty, t_0)$	162

LISTA DE ABREVIATURAS E SIGLAS

B3 – Modelo de Bazant e Baweja (2000)

GL2000 – Modelo de Gardner e Lockman (2001)

EC2 – Modelo Eurocode 2 (2003)

NBR6118 – Modelo norma técnica brasileira de 2004

ACI209R – Modelo do Instituto Americano do Concreto de 2008 ou ACI – American Concrete Institute

MEF – Método de Elementos Finitos

AR – Autorregressivo

MA – Médias Móveis

ARIMA – Autorregressivo Integrado de Médias Móveis

ARIMAX – Autorregressivo Integrado de Médias Móveis com Variáveis Exógenas

SARIMA – Autorregressivo Integrado de Médias Móveis Sazonal

SARIMAX – Autorregressivo Integrado de Médias Móveis Sazonal com Variáveis Exógenas

MAE - Mean Absolute Error

MAPE – Mean Absolute Percentage Error

RMSE – Root Mean Square Error

AIC – Akaike Information Criterion

BIC – Bayesian Information Criterion

SBIC – Schwarz Bayesian Information Criterion

ADF – Augement Dickey-Fuller

KPSS – Kwiatkowski-Phillips-Schmidt-Shin

FAC – Função de Autocorrelação

FACP – Função de Autocorrelação Parcial

MQO – Mínimos Quadrados Ordinários

LMS – Least Mean Square ou MQM – Mínimos Quadrados Médios

SVD – Singular Value Decomposition

SSA – Singular Spectrum Analysis

RNA – Rede Neural Artificial

MLP – Multilayer Perceptron

RBF – Radial Basis Function

RNN – Recurrent Neural Network

DL – Deep Learning

LSTM – Long Short-Term Memory

SUMÁRIO

1	INTRODUÇÃO	19
1.1	O PROBLEMA	21
1.2	OBJETIVOS	22
1.2.1	Objetivo Geral.....	22
1.2.2	Objetivos Específicos	23
1.3	JUSTIFICATIVA.....	24
1.4	ESTRUTURA DA TESE	25
2	REVISÃO DA LITERATURA	26
2.1	DEFORMAÇÕES DO CONCRETO.....	26
2.1.1	MODELOS EMPÍRICOS PARA PREDIÇÃO DA FLUÊNCIA.....	31
2.2	SÉRIES TEMPORAIS	39
2.2.1	METODOLOGIA BOX & JENKINS	40
2.2.2	DECOMPOSIÇÃO DE UMA SÉRIE TEMPORAL.....	46
2.2.3	METODOLOGIA DE REDES NEURAIS ARTIFICIAIS (RNAs)	50
2.2.3.1	REDES NEURAIS RECORRENTES	53
2.2.4	COMBINAÇÃO DE MÉTODOS DE PREDIÇÃO.....	56
2.2.5	BOOTSTRAP	59
2.2.6	INTERVALOS DE CONFIANÇA.....	61
3	MATERIAIS E MÉTODOS	62
3.1	MÉTODO PROPOSTO.....	63
3.2	ETAPAS DO MÉTODO	66
4	RESULTADOS E DISCUSSÕES	70
4.1	ROSETA RD-D09-D57	72
4.2	ROSETA RD-D010-D57	82
4.3	ROSETA RD-D011-D57	92
4.4	ROSETA RD-D012-D57	102
4.5	ROSETA RD-D013-D57	112
5	CONCLUSÃO E CONSIDERAÇÕES FINAIS.....	125
6	REFERÊNCIAS.....	128
7	APÊNDICES.....	137
8	ANEXOS	143

8.1	MODELO B3.....	143
8.2	MODELO EUROCODE 2 (EC2) 2003	146
8.3	MODELO ACI 209R (2008)	151
8.4	MODELO GARDNER E LOCKMAN (2001) – GL2000	153
8.5	MODELO NBR6118 (2004)	155

1 INTRODUÇÃO

A modelagem de dados numéricos foi desenvolvida a partir da década de 1930 com a publicação do primeiro volume da revista *Econométrica* em 1933. Desde então, a modelagem estatística se intensificou dentre outros objetivos para testar teorias econômicas (DINIZ et al., 2013).

Sobre a modelagem de séries temporais os primeiros estudos surgiram com George Udny Yule, que lançou as primeiras ideias de que uma série temporal pode ser gerada por um conjunto de variáveis aleatórias conjuntamente distribuídas. Aplicou modelos autorregressivos (AR) e, em 1937, foram introduzidos os modelos médias móveis (MA) por (SLUTZKY, 1937).

No início da década de 1950, Henry Markowitz foi um dos pioneiros a desenvolver um modelo estatístico para uso financeiro, sendo utilizado para medir o efeito da diversificação no risco total de uma carteira de ativos (MARKOWITZ, 1952).

A modelagem de séries temporais teve grande avanço na década de 1970, quando foi desenvolvida por George Box e Gwilym Jenkins a metodologia que fez a integração dos modelos autorregressivos e médias móveis, conhecida como metodologia Box & Jenkins (BOX e JENKINS, 1976). Esta metodologia se propagou pelo mundo das ciências abrangendo as áreas econômicas, ambientais, da saúde, engenharias, dentre outras, tanto em dissertações, teses e artigos científicos.

Outro importante tipo de modelagem de dados numéricos que surgiu na década de 1940 foi a de Redes Neurais Artificiais (RNAs). Os primeiros estudos e trabalhos foram apresentados em 1943 por McCulloch-Pitts (MCCULLOCH e PITTS, 1990). Apesar de ser baseada no funcionamento dos neurônios humanos, a ideia era muito básica e intuitiva e não apresentava um algoritmo com capacidade de aprendizagem para a rede.

Nas décadas subsequentes, vários algoritmos foram desenvolvidos com o objetivo de ajustar uma rede neural, com destaque para o algoritmo *perceptron*, com uma única camada oculta para modelar problemas não lineares separáveis, desenvolvido por Resenblatt (ROSENBLATT, 1958). Na década de 1980, foram produzidos os principais trabalhos sobre a teoria de aprendizagem das RNAs. Kohonen (1982) apresentou o trabalho sobre os mapas auto organizáveis e Rumelhart et al. (1986) publicaram no livro *Parallel Distributed Processing* o algoritmo de retro propagação, denominado *backpropagation* proposto por Werbos (1974) e

que se tornou o algoritmo de aprendizagem mais utilizado nos modelos de RNAs estática multicamadas.

Na década de 1980, Robinson e Fallside (1987) apresentaram trabalhos sobre redes neurais recorrentes. Estes autores são considerados os precursores deste tipo de rede neural, cujas características principais são as interações entre os neurônios da camada oculta, que possibilita o treinamento e predição de séries temporais de processos de alta complexidade, obtendo melhor acurácia em relação aos tipos de redes tradicionais *Multilayer Perceptron (MLP)* e *Radial Basis Function (RBF)*. Na década de 1990 as redes neurais recorrentes tiveram maior avanço ao serem desenvolvidas as redes *Deep Learning (DL)* com arquitetura *Long Short-Term Memory (LSTM)* que têm uma memória interna longa de curto prazo em que as entradas anteriores são consideradas como dados da própria série temporal (HOCHREITER e SCHMIDHUBER, 1997).

Desde então, com os avanços tecnológicos e computacionais, a modelagem de dados numéricos tem sido aplicada amplamente nas várias áreas da ciência, e tem obtido resultados eficientes e robustos.

Na engenharia civil, por exemplo, a modelagem de dados numéricos tem sido aplicada para reconhecer padrões de fenômenos físicos, em particular as deformações do concreto, sobretudo em obras de grande porte, como barragens, onde fica mais difícil compreender, modelar e prever os detalhes dos seus comportamentos estruturais.

Em todo tipo de barragens, a segurança das estruturas é de fundamental importância. Diante disso, na hidrelétrica de Itaipu foram instalados cerca de 2400 instrumentos de medição e leitura dos fenômenos que ocorrem na barragem e na fundação da mesma, em vários blocos da barragem chamados de blocos instrumentados. Estes instrumentos fornecem importantes informações de ordem preventiva para que a equipe técnica possa avaliar as alterações e realizar as correções adequadas.

Um dos fenômenos que ocorrem no concreto, ao longo do tempo, são as deformações e têm sido objeto de pesquisa, a nível mundial a partir da segunda metade do século XX na construção civil, de modo geral, e em barragens de concreto de usinas hidrelétricas.

As deformações são consideradas como um fenômeno de alta complexidade devido aos muitos fatores que influenciam, tais como: fatores geométricos –

dimensões da estrutura de concreto; fatores ambientais – temperatura ambiente e umidade relativa do ar; agregados da massa do concreto – relação água/cimento (MEHTA e MONTEIRO, 2008).

Construída na década de 1970 no rio Paraná, a usina hidrelétrica de Itaipu, na fronteira de Foz do Iguaçu no Brasil com Ciudad del Este no Paraguai, é um exemplo emblemático de uma grande obra. É a maior hidrelétrica em geração de energia elétrica do mundo, com 20 turbinas e capacidade máxima instalada de 14000 MW de energia elétrica (ITAIPU, 2009). A barragem da referida usina é formada por três partes distintas: barragem de terra, de enrocamento e de concreto. A parte da barragem de concreto é a que tem a maior profundidade (do reservatório). Na parte mais profunda chega a 220 m, trecho central da barragem, onde estão localizados os condutos forçados (ITAIPU, 2009).

A hidrelétrica de Itaipu dispõe de dados históricos das deformações do concreto, da temperatura ambiente e da temperatura do concreto. As deformações e a temperatura do concreto são medidas por rosetas de deformímetro, instaladas nos blocos instrumentados.

Sendo assim, neste trabalho é apresentado um método híbrido em séries temporais, denominado SARIMAX-NEURAL, para modelar e prever as deformações do concreto levando em consideração os efeitos da temperatura ambiente sobre estas, com dados provenientes de rosetas de deformímetro instaladas no bloco D57 da referida usina.

A organização desta pesquisa consta de introdução, descrição do problema da deformação diferida do concreto, justificativa, objetivos da pesquisa, revisão da literatura e referencial teórico, material e métodos, modelo híbrido SARIMAX-NEURAL, discussão dos resultados e conclusões.

1.1 O PROBLEMA

No processo de segurança estrutural de barragens hidrelétricas, pesquisar a deformação por fluência no concreto tem sido de fundamental importância, como medida preventiva a evolução das deformações do concreto. Porém, devido à complexidade deste fenômeno, os modelos considerados de referência já publicados apresentam limitações na precisão ao serem comparados com dados experimentais.

Os principais modelos de referência citados são: O modelo B3 (Bažant e Baweja, 2000), modelo GL2000 (Gardner e Lockman, 2001), modelo Eurocode 2 EC2 (CEN, 2004), modelo NBR6118 (ABNT, 2004) e modelo ACI (ACI209.2-R08, 2008). Segundo Kataoka (2010), não há um consenso entre os pesquisadores sobre este tema, especialmente em relação ao coeficiente de fluência mais adequado.

A fluência do concreto é um fenômeno que ocorre ao longo do tempo, no entanto, nem todos os parâmetros dos modelos supracitados são dependentes do tempo. Por exemplo, os parâmetros geométricos (dimensões das estruturas) e os parâmetros da mistura da massa do concreto (água, cimento, agregados miúdo e graúdo), são parâmetros fixos. Porém, a temperatura ambiente e a umidade relativa do ar são parâmetros que variam com o tempo. Mesmo que os referidos modelos considerem, na modelagem, a temperatura ambiente (caso da NBR 6118 e do modelo B3), ela é utilizada como um parâmetro fixo e não variável ao longo do tempo.

Como a usina hidrelétrica de Itaipu dispõe de dados históricos das deformações do concreto (e não da fluência propriamente dita), tratá-los como séries temporais, possibilita identificar a influência da temperatura ambiente na referida deformação, especialmente porque a variação da temperatura ambiente, entre inverno e verão na barragem de concreto da usina hidrelétrica de Itaipu, é de grande relevância. A temperatura ambiente anual varia em média 23,5 °C. Em 2005 a temperatura mínima foi de 1 °C e máxima de 37,5 °C, conforme dados do (INPE, 2017). Tendo em vista tal amplitude de variação de temperatura como um fator relevante nas deformações do concreto, torna-se necessária uma investigação acerca do caso.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Desenvolver um método de predição híbrido para analisar a aplicabilidade em séries temporais univariadas, que integra a metodologia Box & Jenkins com as Redes Neurais Artificiais Recorrentes Deep Learning, para prever as deformações corrigidas do concreto em barragens de contraforte.

1.2.2 Objetivos Específicos

- a) Propor um método híbrido de predição de séries temporais univariadas, denominado SARIMAX-NEURAL, como uma combinação linear dos modelos autorregressivos integrados de médias móveis com variáveis exógenas e redes neurais recorrentes Deep Learning com arquitetura LSTM;
- b) Fazer predições pontuais das séries temporais das deformações corrigidas do concreto, influenciadas pela temperatura ambiente, modeladas pelo método híbrido proposto;
- c) Comparar as predições obtidas com o método híbrido em relação a predição de cada modelo individual (SARIMA, RNN DL-LSTM e SARIMAX);
- d) Obter o intervalo de confiança das predições, das séries temporais das deformações do concreto influenciadas pela temperatura ambiente, do método proposto por meio do método Bootstrap;
- e) Analisar o comportamento das deformações corrigidas do concreto a partir da projeção futura da curva de tendência da série temporal das deformações.

1.3 JUSTIFICATIVA

Os modelos empíricos desenvolvidos para modelar e prever a fluência do concreto consideram, como parâmetros de entrada, os dados de projeto para a simulação. As deformações do concreto são fenômenos afetados por muitas variáveis, físicas e ambientais, que não são constantes no tempo (NEVILLE, 2011).

Na série temporal das deformações do concreto, consta implicitamente, todos os fatores de causa das mesmas. A modelagem de séries temporais considera o processo a partir de dados históricos e não de dados de projeto (como nos modelos empíricos), sobre o mesmo fenômeno da deformação do concreto. Os dados históricos representam o fenômeno real das deformações corrigidas do concreto e, a modelagem destes dados numéricos objetiva obter um modelo de predição do comportamento padrão do fenômeno em questão.

A decomposição de uma série temporal, em outras subséries, é um processo importante para identificar características específicas da referida série temporal, tais como tendência e sazonalidade (MORETTIN e TOLOI, 1981). A curva de tendência da série temporal ilustra o comportamento das deformações plásticas do concreto acrescidas das deformações elásticas do concreto. Sendo assim, a modelagem em séries temporais das deformações do concreto se justifica como uma metodologia consistente e como contribuição científica ao programa de segurança estrutural de barragens à usina hidrelétrica de Itaipu.

Um dos fatores externos que afetam as deformações do concreto é a temperatura ambiente. A partir da série histórica da temperatura ambiente é possível estudar seu impacto nas deformações do concreto considerando-a como uma variável exógena ou variável explicativa, na modelagem de predição das referidas deformações.

Na aplicação da metodologia Box & Jenkins, os modelos ARIMAX e SARIMAX, possibilitam o estudo e análise que as variáveis exógenas têm no modelo ajustado de uma série temporal univariada. Neste contexto, é necessário que a série temporal seja estacionária de segunda ordem, isto é, com média e variância constantes e que os dados tenham uma estrutura de auto dependência linear. As Redes Neurais Artificiais possibilitam a modelagem de uma série temporal com estrutura de auto dependência não linear dos dados. Assim, na aplicação conjunta destes modelos é possível desenvolver um método híbrido denominado SARIMAX-

NEURAL de séries temporais para prever o fenômeno das deformações corrigidas do concreto, como uma metodologia estatística adequada, capaz de fornecer um conhecimento científico consistente para a modelagem de predição das deformações corrigidas do concreto.

1.4 ESTRUTURA DA TESE

Esta tese está estruturada em seis capítulos: (1) Introdução; (2) Revisão da Literatura; (3) Materiais e Métodos; (4) Discussão e Resultados, (5) Conclusão e considerações Finais e (6) Referências Bibliográficas. No capítulo 2 são descritos os modelos empíricos das deformações, por fluência, do concreto mais citados na literatura, conforme citado na seção 1.1. Também são definidos os conceitos dos métodos e técnicas, metodologia Box & Jenkins e metodologia de redes neurais recorrentes Deep Learning, utilizadas no desenvolvimento deste trabalho de tese.

No capítulo 3 são apresentados os materiais (séries históricas das deformações corrigidas do concreto e da temperatura ambiente disponibilizadas pela Itaipu Binacional) e a descrição do método híbrido proposto, chamado SARIMAX-NEURAL. No capítulo 4 são apresentados e discutidos os resultados das simulações numéricas do método híbrido e dos métodos individuais SARIMA, SARIMAX e redes neurais recorrentes *Deep Learning* com arquitetura *LSTM*. No capítulo 5 são apresentadas as conclusões e sugestões para trabalhos futuros, no capítulo 6 estão as referências bibliográficas utilizadas nesta tese e no capítulo 7 estão os apêndices e anexos.

2 REVISÃO DA LITERATURA

Neste capítulo são apresentados os conceitos dos modelos empíricos que modelam a curva de fluência e também os conceitos e técnicas que fundamentam a descrição do método híbrido SARIMAX-NEURAL proposto nesta tese.

2.1 DEFORMAÇÕES DO CONCRETO

Esta revisão da literatura se destina ao relato sobre a importância do estudo das deformações do concreto, considerando que neste trabalho se dá ênfase à análise numérica, sem se aprofundar nos aspectos da engenharia.


Segundo Neville (2011), no concreto sob carregamento há três tipos principais de deformações ao longo do tempo: deformações elásticas – sempre reversíveis; deformações visco-elásticas – parcialmente reversíveis, sendo uma fase elástica e outra viscosa; deformações plásticas – são sempre irreversíveis. A deformação elástica tem uma parte instantânea e outra retardada – na deformação elástica instantânea a relação tensão deformação é regida pela Lei de Hooke, porém, a deformação elástica retardada é dependente do tempo.

A deformação plástica tem uma parte instantânea e outra viscosa – na parte instantânea a deformação plástica não apresenta variação de volume do concreto, neste caso, não há proporcionalidade entre deformação plástica e tensão aplicada ou entre tensão e velocidade de deformação. Na deformação viscosa, que é dependente do tempo, há proporcionalidade entre a velocidade de deformação viscosa e a tensão aplicada (NEVILLE, 2011).

Andriolo e Sgarboza (1993) definem o material concreto como uma mistura convenientemente proporcionada de vários materiais particularmente o que é formado por cimento Portland, água, areia, e agregado natural ou britado. Por ser constituído de uma mistura, devido às reações químicas que ocorrem entre seus componentes, apresenta uma estrutura interna que sofre alterações no seu volume (retração ou expansão).

Conforme Araújo (2002), o concreto de forma geral apresenta ao longo do tempo dois tipos de deformação denominadas deformações diferidas que são:

deformação por retração e deformação lenta ou fluência. Neville (2011) diz que a fluência do concreto pode ser entendida como o aumento da deformação com uma carga constante ao longo do tempo e pode ser classificada como fluência básica e fluência por secagem. A fluência básica ocorre quando não há transferência de água entre o concreto e o meio ambiente, isto é, ocorre internamente na massa do concreto e a fluência por secagem é a que ocorre quando há transferência de água para o meio ambiente. Neville (2011) afirma ainda que a fluência é, geralmente, representada em termos de fluência específica, que é a deformação por fluência por unidade de tensão ($\times 10^{-6}/\text{MPa}$). A FIGURA 1 representa teoricamente a forma da curva de fluência.




FONTE: Mehta e Monteiro (2008)

A retração do concreto, após o seu endurecimento, ocorre sem o efeito de carga e pode ser classificada segundo Equipe de Furnas (1997), Kalintzis (2000), Neville (2011) e Mehta e Monteiro (2008) como: retração plástica, retração autógena, retração por secagem e retração por carbonatação. A retração autógena é definida como a redução do volume do concreto na hidratação do cimento após o início da pega e tende a aumentar devido a temperaturas muito altas, maiores teores de cimentos e relação água/cimento menores (NEVILLE, 2011). A retração por secagem do concreto decorre da variação e/ou perda de umidade para o meio ambiente das pastas de cimento e argamassa, sendo uma das principais causas de fissuração do

concreto, podendo afetar sua durabilidade (EQUIPE DE FURNAS, 1997 e KALINTZIS, 2000). A FIGURA 2 ilustra a deformação por retração e sua reversibilidade.


FIGURA 2 - REVERSIBILIDADE DA RETRAÇÃO



FONTE: Mehta e Monteiro (2008)

Nunes e Figueiredo (2007) relatam que os agregados da massa do concreto têm grande influência sobre a retração do concreto e que o módulo de deformação destes agregados tem influência direta na retração do concreto. Através de experimentos realizados Pickett (1956) mostrou que quanto maior a fração volumétrica de agregado no concreto, menor foi a retração por secagem, como mostra a FIGURA 3.

FIGURA 3 - RELAÇÃO ENTRE A FRAÇÃO VOLUMÉTRICA DO CONCRETO E A RETRAÇÃO DO CONCRETO

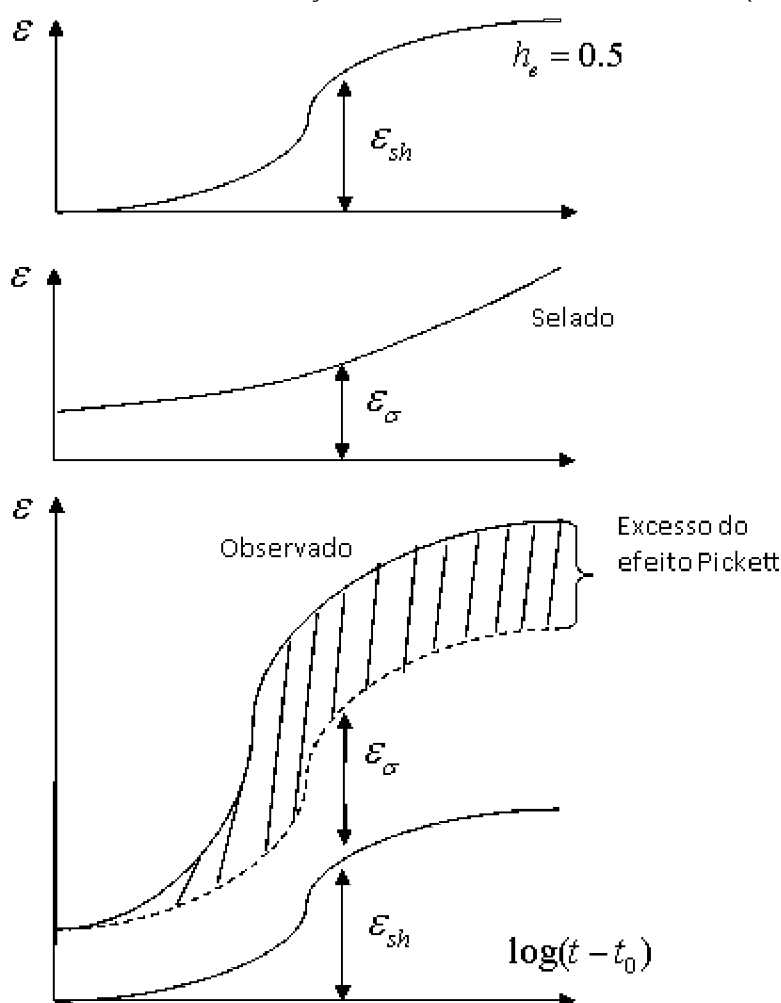


FONTE: Pickett (1956)

Um agregado com baixo módulo de deformação ocasiona um aumento na deformação por retração e a substituição de um agregado com alto módulo de deformação por outro agregado com menor módulo de deformação pode acarretar um aumento da retração por secagem de até 2,5 vezes (MEHTA e MONTEIRO, 1994).

Conforme Pickett (1942) apud Bažant (1988), o efeito Pickett é caracterizado pela deformação produzida por secagem. Este efeito pode ser controlado em corpos de prova selados, porém em construções como barragens de concreto o efeito Pickett não pode ser desconsiderado (como é o caso da barragem de Itaipu). Neville (2011) diz que o efeito Pickett corresponde à fluência por secagem. A FIGURA 4 apresenta uma ilustração do efeito Pickett.


FIGURA 4 - EXCESSO DE DEFORMAÇÃO PRODUZIDA POR SECAGEM (EFEITO PICKETT)



FONTE: Bažant (1988)

Para Costa Neto (2004) pode ocorrer ainda uma combinação entre elas como deformações elasto-plásticas ou visco-elásticas, de forma que torna complexo o entendimento da combinação dessas deformações. A elasticidade retardada que ocorre ao longo do tempo pode ser considerada como uma forma de fluência e é completamente reversível, já que a energia produzida não é dissipada e sim armazenada no material, porém, a deformação plástica é totalmente irreversível. A FIGURA 5 mostra resumidamente uma projeção teórica destes tipos de fluência.

FIGURA 5 - DEFORMAÇÃO DEPENDENTE DO TEMPO EM CONCRETO SUBMETIDO A CARGA CONSTANTE



FONTE: Neville (2011)

Conforme Kataoka (2010), os fatores que causam a fluência são complexos e, por isso, não há um consenso entre os pesquisadores sobre este assunto. Ela destaca duas hipóteses mencionadas por Neville (2011) na tentativa de explicar as causas da fluência: Movimentação interna da água adsorvida e a espessura das camadas de água adsorvidas. Porém, foi identificada fluência do concreto após 30 anos, contrariando, assim, a segunda hipótese. Isto significa que há outras causas para a fluência além da percolação da água adsorvida.

Segundo Teixeira (2006), a fluência é função de vários fatores que se interagem simultaneamente. Como cada um destes fatores são de extrema complexidade, esta interação é de difícil entendimento. Os principais fatores que afetam a fluência são: umidade do ar – quanto menor a taxa de umidade relativa do ar maior será a deformação por fluência, Equipe de Furnas (1997); intensidade da carga; resistência do concreto – no instante da aplicação da carga, quanto menor a resistência do concreto, maior será a fluência; idade do concreto – à medida que o

concreto envelhece a resistência e o seu módulo de elasticidade aumentam influenciando diretamente na taxa de deformação por fluência; temperatura ambiente – se o concreto for exposto a uma temperatura alta durante o processo de cura e antes de ser carregado, sua resistência aumentará e, conseqüentemente, a deformação por fluência será menor do que a de um concreto mantido a uma temperatura menor; tipo do cimento, relação água/cimento e agregados (NEVILLE, 2011).

Há ainda outros fatores como os aditivos e as dimensões da peça que influenciam nas deformações por fluência. Quanto maior for a intensidade da carga, maior será a deformação por fluência. Os aditivos redutores de água e aceleradores de pega resultam no aumento da fluência em alguns casos e em outros não, por isso, devem ser analisados cuidadosamente (SANTOS, 2002). A Tabela 1, apresenta resumidamente os principais fatores que influenciam na fluência do concreto.

Tabela 1 - FATORES QUE INFLUENCIAM NA FLUÊNCIA DO CONCRETO AO LONGO DO TEMPO

Grupos	Fatores
Fatores ambientais	Umidade relativa do ar, Temperatura do ar, Ventilação e Radiação solar
Fatores materiais	Tipo de cimento, relação A/C, % de pasta, aditivos, agregados e f_{ck}
Fatores geométricos	Forma e espessura média
Fatores mecânicos	Intensidade do carregamento
Fatores temporais	Idade do concreto Idade do concreto no carregamento Tempo de carregamento

FONTE: Adaptado de Santos (2002)

2.1.1 MODELOS EMPÍRICOS PARA PREDIÇÃO DA FLUÊNCIA

Conforme Bazant e Baweja (2000), a modelagem real da fluência e retração do concreto é muito difícil, pois, é resultado da interação de diversos mecanismos físicos e serem influenciados por muitos parâmetros. Kataoka (2010) destaca que desde 1982 vários modelos matemáticos foram propostos, para a modelagem da fluência e retração do concreto tais como os citados na seção 1.1.

Cada um destes modelos tem a sua complexidade em relação a quantidade de dados de entrada, considerando as diferentes características de cada tipo de concreto, conforme TABELA 2, assim como, os diversos fatores que influenciam a fluência já mencionados nesta revisão.

TABELA 2 - PARÂMETROS DE ENTRADA DOS MODELOS DE FLUÊNCIA (F*) E RETRAÇÃO (R*)

Modelos	ACI		EC2		B3		GL		NBR	
Parâmetros	F*	R*	F*	R*	F*	R*	F*	R*	F*	R*
Tipo de cimento	✓		✓	✓	✓	✓	✓	✓	✓	
Umidade relativa (%)	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Idade carregamento/fim cura (dias)	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Método de cura	✓	✓			✓	✓				
Volume/superfície	✓	✓			✓	✓	✓	✓		
Área/perímetro			✓	✓					✓	✓
Dimensões do CP (cm)	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Secagem antes carregamento (dias)				✓	✓		✓	✓		
f_{cm0} (MPa)	✓		✓				✓		✓	
f_{ck} (MPa)				✓						
f_{cm28} (MPa)	✓		✓	✓	✓	✓	✓	✓	✓	
E_{cm0} (MPa)	✓		✓		✓		✓		✓	
E_{cm28} (MPa)	✓		✓		✓	✓	✓		✓	
Resistência agregado			✓							
Quantidade agregado total (kg/m ³)					✓					
Consumo cimento (kg/m ³)		✓			✓					
Quantidade de água (kg/m ³)					✓	✓				
Agregado miúdo (%)	✓	✓								
Abatimento (mm)	✓	✓							✓	✓
Temperatura (°C)			✓	✓	✓	✓			✓	✓
Volume de ar (%)	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Tipo de agregado	✓									

FONTE: Adaptado de Kataoka (2010)

A TABELA 3 mostra as proporções em relação aos respectivos parâmetros de cada modelo empírico de predição da fluência.

TABELA 3 - LIMITAÇÃO DOS MODELOS DE FLUÊNCIA E RETRAÇÃO					
Dados	ACI	EC2	B3	GL	NBR
f_{cm28} (MPa)	-	20 a 90	17 a 70	0 a 70	-
f_{ck} (MPa)	-	-	-	-	20 a 50
Agregado/cimento	-	-	2,5 a 13,5	-	-
Tensão aplicada (%)	0 - 40	0 - 45	0 - 45	0 - 40	0 - 40
Consumo de cimento (kg/m ³)	-	-	160 - 720	-	300 -
Água/cimento	-	-	0,35 - 0,85	0,4 - 0,6	-
Umidade relativa (%)	40 a 100	40 a 100	40 a 100	40 a 100	40 a 100
Temp cura úmida (dias)	> 7	< 14	-	> 2	-

FONTE: Kataoka (2010)

Kataoka (2010) alerta ainda para o fato de que na comparação dos modelos estatísticos com os dados experimentais de fluência e retração, um dos problemas que ocorre é que à medida que as deformações por fluência e retração evoluem com o tempo, a dispersão dos dados aumenta. Por exemplo, na utilização de modelos de regressão linear, o peso dos dados experimentais relativos, as primeiras idades do concreto, é menor do que em idades mais avançadas. Já quando a análise de comparação dos modelos é feita dos dados experimentais utilizando os desvios, ocorre o contrário, isto é, o peso maior é dado para idades menores (VIDELA, 2006).

Na comparação entre os dados experimentais de fluência e retração com os modelos de predição, os métodos estatísticos mais utilizados, segundo Kataoka (2010), são:

- Comparação individual da curva do modelo de predição com os resultados experimentais de cada grupo;
- Utilização de modelos e regressão linear para comparar os resultados com os dados experimentais. Salienta-se que neste tipo de comparação, rapidamente pode-se identificar a precisão do modelo, utilizando o coeficiente de correlação múltipla R^2 . Porém, há o problema dos pesos, já mencionado.
- Avaliação dos resíduos. A comparação é feita pela diferença entre os resultados experimentais e os dados modelados (um a um), considerando

que os valores positivos e negativos indicam que o modelo superestima ou subestima os resultados experimentais, respectivamente.


- d) Análise do coeficiente de variação. Há vários coeficientes de variação, conforme Videla (2006), os indicadores estatísticos mais aceitos são: coeficiente de variação (ω_{B3}) do modelo B3; coeficiente de variação CBE (V_{CEB}) e coeficiente de variação (ω_G) do modelo GL de GARDNER (2004).

Conforme ACI209R-R92 (1992) Committee *apud* Videla (2006), não há um coeficiente de variação disponível, como indicador estatístico que seja consenso na literatura, devido aos diferentes parâmetros que cada modelo contempla.

No caso da usina hidrelétrica de Itaipu, as deformações do concreto são medidas por deformímetros, dispostos em forma de rosetas, instalados em blocos de concreto, chamados blocos chave ou blocos instrumentados. A FIGURA 6 mostra a forma tridimensional de uma das rosetas de deformímetro, com cinco braços ou direções correspondentes, instaladas em um dos blocos chave da barragem de Itaipu.

Cada braço da roseta tem um deformímetro que está em um plano e permite determinar as tensões e as deformações nas direções de cada braço deste plano. Seu funcionamento se baseia na relação linear existente entre a tensão aplicada e a resistência elétrica de um fio de aço. Os braços 1, 2, 3 e 4, que formam um ângulo de 45°, são coplanares ao sentido ao fluxo, ou seja, de montante para jusante, onde o braço 1 é posicionado em direção a jusante e o braço 5 na direção normal ao fluxo, sendo este último coplanar ao braço 3, formando um ângulo de 90° entre eles (MATOS, 2002).


FIGURA 6 - ROSETA DE DEFORMÍMETRO



FONTE: Acervo Técnico de Itaipu (2018)

Cada deformímetro (ver FIGURA 7) mede as tensões de forma indireta através das deformações sofridas pelo concreto. Além das deformações e das tensões este aparelho mede também a temperatura do concreto.

FIGURA 7 - REPRESENTAÇÃO DE UM DEFORMÍMETRO



FONTE: Acervo de Itaipu (2018)

As deformações são determinadas pela relação de resistências entre as duas bobinas, fixadas a duas barras de aço que transmitem as solicitações da estrutura. Quando ocorre algum tipo de deformação a resistência de uma bobina aumenta enquanto a outra diminui na mesma proporção. Quando ocorre variações de temperatura, as resistências sofrem variações de comprimento muito semelhantes, assim, a variação de resistência não é afetada pela temperatura.

A tensão a ser calculada pelo deformímetro deve ser proveniente apenas das deformações ocasionadas por cargas aplicadas no concreto. Dessa forma é necessário que as deformações ocasionadas pela variação de temperatura, umidade, reações químicas e outras sejam corrigidas (daí a expressão **deformações corrigidas** do concreto). Por isso, se faz necessário a colocação de um deformímetro corretor, livre do campo de tensões e que forneça as variações de comprimento devido a solicitações diferentes das de carregamento. Este aparelho é instalado em uma caixa a tensorial e preenchida com o mesmo concreto que envolve a roseta. A FIGURA 8 mostra a instalação de um balde a tensorial e também de uma roseta de deformímetro em um bloco de contraforte.


FIGURA 8 - BALDE A TENSORIAL E MAIS AO FUNDO UMA ORSETA DE DEFORMÍMETRO



FONTE: Acervo de Itaipu (2018)

A disposição de cada roseta na barragem é conforme o fluxo do reservatório conforme a FIGURA 9.

FIGURA 9 - ROSETAS DE DEFORMÍMETRO INSTALADAS EM UM BLOCO DE CONTRAFORTE



FONTE: Arquivo Técnico de Itaipu (2018)

As deformações corrigidas do concreto (ε) são de ordem mecânica e determinadas através das seguintes equações:

$$\varepsilon'_i = \varepsilon_i - \varepsilon_6 \text{ com } i = 1, \dots, 5 \quad (1)$$

Em que ε_6 é a deformação química medida no balde a tensorial. A soma das deformações, medidas por cada deformímetro, das direções ortogonais no mesmo plano (perpendicular entre si), deve ser constante. Logo, $\varepsilon'_1 + \varepsilon'_3 = \varepsilon'_2 + \varepsilon'_4 = \text{const}$. A correção das deformações segue a seguinte ordem:

A primeira correção é determinada por:

$$\varepsilon''_i = \varepsilon'_i - \left| \frac{(\varepsilon'_1 + \varepsilon'_3) - (\varepsilon'_2 + \varepsilon'_4)}{4} \right| \text{ com } i = 1, \dots, 4 \quad (2)$$

A segunda correção, causada pelo efeito de Poisson (ν), é feita aplicando a teoria da elasticidade tal que as deformações corrigidas (ε^c) são representadas por:

$$\varepsilon^c_i = \frac{1}{(1+\nu)(1-2\nu)} \left[(1-\nu)\varepsilon''_i + \nu(\varepsilon''_j + \varepsilon''_k) \right] \quad (3)$$

Considerando o coeficiente de Poisson $\nu = 0,2$, tem-se:

$$\varepsilon^c_1 = 1,11\varepsilon''_1 + 0,28(\varepsilon''_3 + \varepsilon''_5) \quad (4)$$

$$\varepsilon^c_2 = 1,11\varepsilon''_2 + 0,28(\varepsilon''_4 + \varepsilon''_5) \quad (5)$$

$$\varepsilon^c_3 = 1,11\varepsilon''_3 + 0,28(\varepsilon''_1 + \varepsilon''_5) \quad (6)$$

$$\varepsilon^c_4 = 1,11\varepsilon''_4 + 0,28(\varepsilon''_2 + \varepsilon''_5) \quad (7)$$

$$\varepsilon^c_5 = 1,11\varepsilon''_5 + 0,28(\varepsilon''_2 + \varepsilon''_3) \quad (8)$$

Finalmente, deve ser confirmado que:

$$\varepsilon^c_1 + \varepsilon^c_3 = \varepsilon^c_2 + \varepsilon^c_4 = \text{const} \quad (9)$$

Nos modelos matemáticos empíricos descritos nesta revisão de literatura, destaca-se a ênfase na obtenção de um coeficiente de fluência e uma função de fluência para aproximar uma curva de fluência, a partir de dados de projeto. Desta forma, pode-se comparar com dados experimentais, de ensaio de fluência, obtidos de corpos de prova na forma cilíndrica, de 30 cm de comprimento e diâmetro de 15 cm (KATAOKA, 2010).

Um dos fatores ambientais que influenciam na deformação por fluência é a temperatura ambiente. No entanto, nas simulações dos modelos empíricos é considerada a temperatura ambiente constante, embora, possa variar, mas de uma simulação para outra e não na mesma simulação. A temperatura ambiente é uma variável que afeta a fluência, pelo fato que no concreto ocorre um processo de hidratação contínuo no tempo (NEVILLE, 2011). Neste aspecto, nos modelos empíricos, não é estudado o impacto da temperatura ambiente variável na fluência do concreto. A ênfase está na determinação do coeficiente de fluência e na função de fluência para ajustar a curva de fluência.

No anexo A são apresentadas as descrições dos modelos empíricos citados na TABELA 2 da subseção 2.1.1.

2.2 SÉRIES TEMPORAIS

De modo geral uma série temporal é definida como um conjunto de dados numéricos ordenados no tempo e que pode apresentar as características básicas, que são: tendência (T), sazonalidade (S), ciclo (C) e componente aleatória (I). Estas características podem ser identificadas pela decomposição da referida série temporal. A predição de uma série temporal Z_t , em um horizonte de predição h é feita a partir do tempo t como origem da predição, isto é, tem-se Z_t e deseja-se prever Z_{t+h} , de duas formas: predição estática ou direta e predição dinâmica ou recursiva (MORETTIN e TOLOI, 1981).

Na predição estática ou direta, considera-se conhecido o valor real da variável Z no instante t para o cálculo da predição um passo à frente (MORETTIN e TOLOI, 1981). A predição é feita no mesmo modelo de predição definido. Por exemplo, para fazer uma predição direta, com um horizonte de predição ($h = 3$). Seja uma série temporal $Z_t = \{z_1, z_2, \dots, z_n, z_{n+1}, z_{n+2}, z_{n+3}\}$, tem-se que:

- I. Para uma amostra $Z_t = \{z_1, z_2, \dots, z_n\}$ obtém-se a predição \hat{z}_{n+1} ;
- II. Para uma amostra $Z_t = \{z_1, z_2, \dots, z_n, z_{n+1}\}$ obtém-se a predição \hat{z}_{n+2} ;
- III. Para uma amostra $Z_t = \{z_1, z_2, \dots, z_n, z_{n+1}, z_{n+2}\}$ obtém-se a predição \hat{z}_{n+3} ;

Na predição dinâmica ou recursiva a estimativa dos valores futuros da série é feita com base em suas próprias previsões dos períodos de tempo anteriores, ou seja, as previsões são feitas recursivamente baseadas nas previsões anteriores. Por exemplo, para fazer uma predição recursiva, com um horizonte de predição ($h = 3$), tem-se:

- IV. Para a amostra $Z_t = \{z_1, z_2, \dots, z_n\}$ obtém-se a predição \hat{z}_{n+1} ;
- V. Para a amostra $Z_t = \{z_1, z_2, \dots, z_n, \hat{z}_{n+1}\}$ obtém-se a predição \hat{z}_{n+2} ;
- VI. Para a amostra $Z_t = \{z_1, z_2, \dots, z_n, \hat{z}_{n+1}, \hat{z}_{n+2}\}$ obtém-se a predição \hat{z}_{n+3} ;

2.2.1 METODOLOGIA BOX & JENKINS

A partir da década de 1970 Box & Jenkins apresentaram uma metodologia consistente na tentativa de melhorar a acurácia na modelagem de séries temporais. Esta metodologia consiste em ajustar modelos autorregressivos integrados de médias móveis, denominado ARIMA, a um conjunto de dados a partir de três estágios: identificação do modelo, estimação dos parâmetros e verificação ou validação do modelo ajustado (BOX e JENKINS, 1976).

Amplamente aplicada nas mais diversas áreas do conhecimento, a metodologia de Box & Jenkins é recomendada para séries temporais resultantes de processos estocásticos lineares. Para séries temporais oriundas de processos não lineares são indicados outros métodos, normalmente Redes Neurais Artificiais – RNAs, embora, as RNAs também podem ser utilizadas tanto em processos lineares quanto não lineares (HAYKIN, 2001).

A metodologia Box & Jenkins foi desenvolvida com objetivo de identificar um modelo probabilístico a partir de uma série temporal estacionária de segunda ordem, isto é, média e variância constantes. Isto implica que os dados tenham uma estrutura de auto dependência linear ou autocorrelação entre os valores da série temporal (BOX e JENKINS, 1976). O modelo $ARMA(p,q)$ para uma série temporal Z_t estacionária é composto dos modelos Autorregressivos $AR(p)$ e Médias Móveis $MA(q)$, sendo p o parâmetro autorregressivo (tomados p valores anteriores para definir a predição) e q é o parâmetro das médias móveis (tomando a média dos erros dos p valores autorregressivos). O referido modelo é representado por:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = \delta + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (10)$$

Onde $\phi_1, \phi_2, \dots, \phi_p$ e $\theta_1, \theta_2, \dots, \theta_q$ são os parâmetros, autorregressivos e médias móveis, respectivamente, a serem determinados e δ é uma constante do modelo e a_t é o erro ou choque aleatório. A equação (10) está escrita em função do operador B de translação para o passado, ou operador de retardo, definido por: $BZ_t = Z_{t-1}$, $B^2 Z_t = B(BZ_t) = BZ_{t-1} = Z_{t-2}$ e de modo geral: $B^m Z_t = Z_{t-m}$. Na forma padrão, a equação (10), pode ser escrita por:

$$\phi(B)Z_t = \delta + \theta(B)a_t \quad (11)$$

Em que $\phi(B)$ e $\theta(B)$ são os operadores autorregressivos e médias móveis, respectivamente, expressos na forma de polinômios de ordem p e q , respectivamente.

Se a referida série temporal for não estacionária, pode-se obter a estacionariedade (quando possível) por um processo de diferenciação de ordem d (até torná-la estacionária), utilizando o operador diferença (∇), definido por: $\nabla(Z_t) = Z_t - Z_{t-1} = (1-B)Z_t$, Box e Jenkins (1976), segue-se que: $\nabla = 1-B$, gerando, assim, o modelo $ARIMA(p,d,q)$ que é representado, na forma padrão, pela equação:

$$\phi(B)\nabla^d Z_t = \delta + \theta(B)a_t \quad (12)$$

Caso a série temporal apresente sazonalidade, então, o modelo estatístico pode ser dito $SARIMA(p,d,q) \times (P,D,Q)_s$ multiplicativo, em que P é a ordem autorregressiva da parte sazonal, D é a ordem de diferença da parte sazonal (caso a série não seja estacionária) e Q é o parâmetros médias móveis do período sazonal s . A ordem dos parâmetros p , q e d é identificada pela análise do perfil dos gráficos da função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP) conforme (HAMILTON, 1994).

O modelo SARIMA para uma série temporal Z_t não estacionária e com sazonalidade é definido pela equação:

$$\phi(B)\Phi(B^s)(1-B^s)^D(1-B)^d Z_t = \theta(B)\Theta(B^s)a_t \quad (13)$$

Onde

- i) B é operador de translação para o passado ou operador de retardo, m valores, definido como $B^m Z_t = Z_{t-m}$;
- ii) $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é a parte autorregressiva não sazonal, na forma de polinômio, de ordem p ;
- iii) $\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps}$ é a parte autorregressiva sazonal de ordem P e ordem sazonal s ;
- iv) $(1-B^s)^D$ é o operador de diferenciação sazonal de ordem D e ordem sazonal s ;
- v) $(1-B)^d$ é o operador de diferenciação não sazonal de ordem d ;

vi) $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é a parte não sazonal de médias móveis, na forma de polinômio, de ordem q ;

vii) $\Theta(B^s) = 1 - \Theta_1 B^s - \dots - \Theta_Q B^{Qs}$ é a parte sazonal de médias móveis de ordem Q e estação sazonal de ordem s .

Na prática, para a aplicação da modelagem SARIMA, deve-se observar dois princípios fundamentais: o modelo deve ser parcimonioso, isto é, exige o menor número possível de parâmetros para a melhor precisão e o ciclo iterativo que possibilita identificar uma estratégia de seleção de modelos. A estimativa dos parâmetros é feita utilizando métodos iterativos não lineares (método dos mínimos quadrados ordinários) associado com o método da máxima verossimilhança (MORETTIN e TOLOI, 2006).

Na identificação do modelo de predição são utilizados os perfis gráficos da Função de Autocorrelação FAC (*Autocorrelation Function – ACF*), para determinar a ordem dos parâmetros médias móveis (MA), e da função de autocorrelação parcial FACP (*Partial Autocorrelation Function – PACF*), para determinar a ordem dos parâmetros autorregressivos de uma série estacionária, conforme os critérios da TABELA 4, além da utilização do teste de Durbin-Watson (Durbin e Watson (1950)), para verificar a correlação serial de primeira ordem nos resíduos (HAMILTON, 1994).

TABELA 4 - PERFIL GRÁFICO DA FAC E DA FACP PARA MODELOS DE SÉRIES TEMPORAIS ESTACIONÁRIAS DA METODOLOGIA BOX & JENKINS

FAC	FACP
AR(p) - Infinita (exponenciais amortecidas e/ou senóide amortecido). Não se anulam bruscamente.	AR(p) - Finita. Anulam-se bruscamente no lag p.
MA(q) - Finita. Anulam-se bruscamente no lag q.	MA(q) - Infinita (dominada por exponenciais amortecidas e/ou senóide). Não se anulam bruscamente.
ARMA(p,q) - Infinita (exponenciais amortecidas e/ou senóide amortecidos para $k > q - p$). Não se anulam bruscamente.	ARMA(p,q) - Infinita (dominada por exponenciais amortecidas e/ou senóide amortecidos para $k > q - p$). Não se anulam bruscamente.
SAR(P) - Infinita (exponenciais amortecidas e/ou senóide amortecido). Não se anulam bruscamente.	SAR(P) - Finita. Anulam-se bruscamente no lag P.s.
MA(Q) - Finita. Anulam-se bruscamente no lag Q.s.	MA(Q) - Infinita (dominada por exponenciais amortecidas e/ou senóide). Não se anulam bruscamente.
SARMA(P,Q) - Infinita (exponenciais amortecidas e/ou senóide amortecidos para $k > Q - P$). Não se anulam bruscamente.	SARMA(P,Q) - Infinita (exponenciais amortecidas e/ou senóide para $k > Q - P$). Não se anulam bruscamente.

FONTE: Box e Jenkins (1976)

Também deve ser realizada a análise da FAC e FACP dos resíduos quadráticos para identificar a volatilidade da variância através do teste ARCH (ENGLE, 1982).

A utilização de softwares de programação como *Matlab R2018a*, *R* e *Maple 2016* possibilita a realização destes testes de forma rápida e eficiente para identificação da ordem e dos parâmetros do modelo estimado. Para verificar a estacionariedade da média da série temporal são aplicados os testes de raiz unitária ADF – Augment Dickey-Fuller (Dickey e Said, 1984) e KPSS – Kwiatkowski-Phillips-Schmidt-Shin (KWIATKOWSKI et al., 1992). Caso a série temporal não seja estacionária na variância, pode ser aplicado o logaritmo nos dados ou o teste de Box-Cox

(Box e Cox, 1964) para obter a estacionariedade na variância.

A determinação dos coeficientes do modelo estimado, isto é, os parâmetros autorregressivos e médias móveis, é feita por meio de um software (neste trabalho são utilizados os softwares *Matlab* e *R*). Para o cálculo computacional dos parâmetros do modelo estimado são utilizados três métodos:

- Método dos Mínimos Quadrados Ordinários (MQO) – para modelos $AR(p)$;
- Método dos Momentos (por meio das equações de Yule-Walker) – para modelos $MA(q)$;
- Método da Máxima Verossimilhança – para modelos $ARIMA(p, d, q)$ e $SARIMA(p, d, q) \times (P, D, Q)_s$.

Para a validação do modelo estimado é utilizado o teste da Sobrefixação, que consiste em estimar um outro modelo com parâmetros extras para verificar se estes são significativos e se sua inclusão diminui a variância dos resíduos. Através das estimativas dos novos parâmetros é aplicado o teste estatístico “ t ” sobre a hipótese de o parâmetro adicional ser nulo; caso o parâmetro seja significativo, acrescenta-se este novo parâmetro ao modelo estimado (MORETTIN e TOLOI, 1981). De forma resumida pode-se dizer que:

- i) É aceito como adequado o modelo estimado quando o modelo com parâmetros adicionais está sobre-identificando o modelo testado;
- ii) Rejeita a hipótese de o modelo estimado ser adequado, se as estimativas dos parâmetros adicionais forem coerentes.

É importante destacar que na escolha do melhor modelo estimado, também deve ser considerado o princípio da parcimônia, isto é, deve-se escolher o modelo com o menor número de parâmetros. Neste caso, são utilizados os critérios de informação, como: *Akaike Information Criterion – AIC*, DeLeeuw (1973); *Bayesian Information Criterion – BIC* e *Schwarz Bayesian Information Criterion – SBIC* (SCHWARZ, 1978).

Salienta-se também que na validação do modelo estimado se deve realizar a análise dos resíduos. Para isto é importante verificar a estacionariedade dos resíduos aplicando os testes ADF e KPSS. São utilizados vários testes de autocorrelação residual tais como: teste de Box-Pierce (Box e Pierce, 1970) e o teste de Ljung-Box (LJUNG e BOX, 1978). Para verificar a normalidade dos resíduos é aplicado o teste de Shapiro-Wilk, (Shapiro e Wilk, 1965), ou seja, se os resíduos são aleatórios, isto é, são independentes e identicamente distribuídos (*i.i.d*), formando um ruído branco com distribuição de probabilidade $a_t \sim N(0, \sigma^2)$, aliado a análise do periodograma acumulado dos resíduos, que foi um dos primeiros estimadores da análise espectral de séries temporais (MORETTIN e TOLOI, 1981). Outro recurso importante utilizado na validação do modelo estimado é calcular os erros *Root Mean Square Error – RMSE*, *Mean Absolute Error – MAE* e *Mean Absolute Percentage Error – MAPE*.

A metodologia Box & Jenkins univariada também admite que se utilize variáveis exógenas (ou variáveis explicativas) na composição do modelo estimado, possibilitando o estudo do impacto destas variáveis no modelo de predição. Com isso, agrega-se aos modelos ARIMA e SARIMA mais informações acerca de determinado fenômeno físico ou econômico. A inclusão de variáveis exógenas X_r no modelo (12) gera o modelo $ARIMAX(p, d, q, r)$, Box et al. (1994), definido por:

$$\phi(B)\nabla^d Z_t = \delta + \beta(1-B)^d X_r + \theta(B)a_t \quad (14)$$

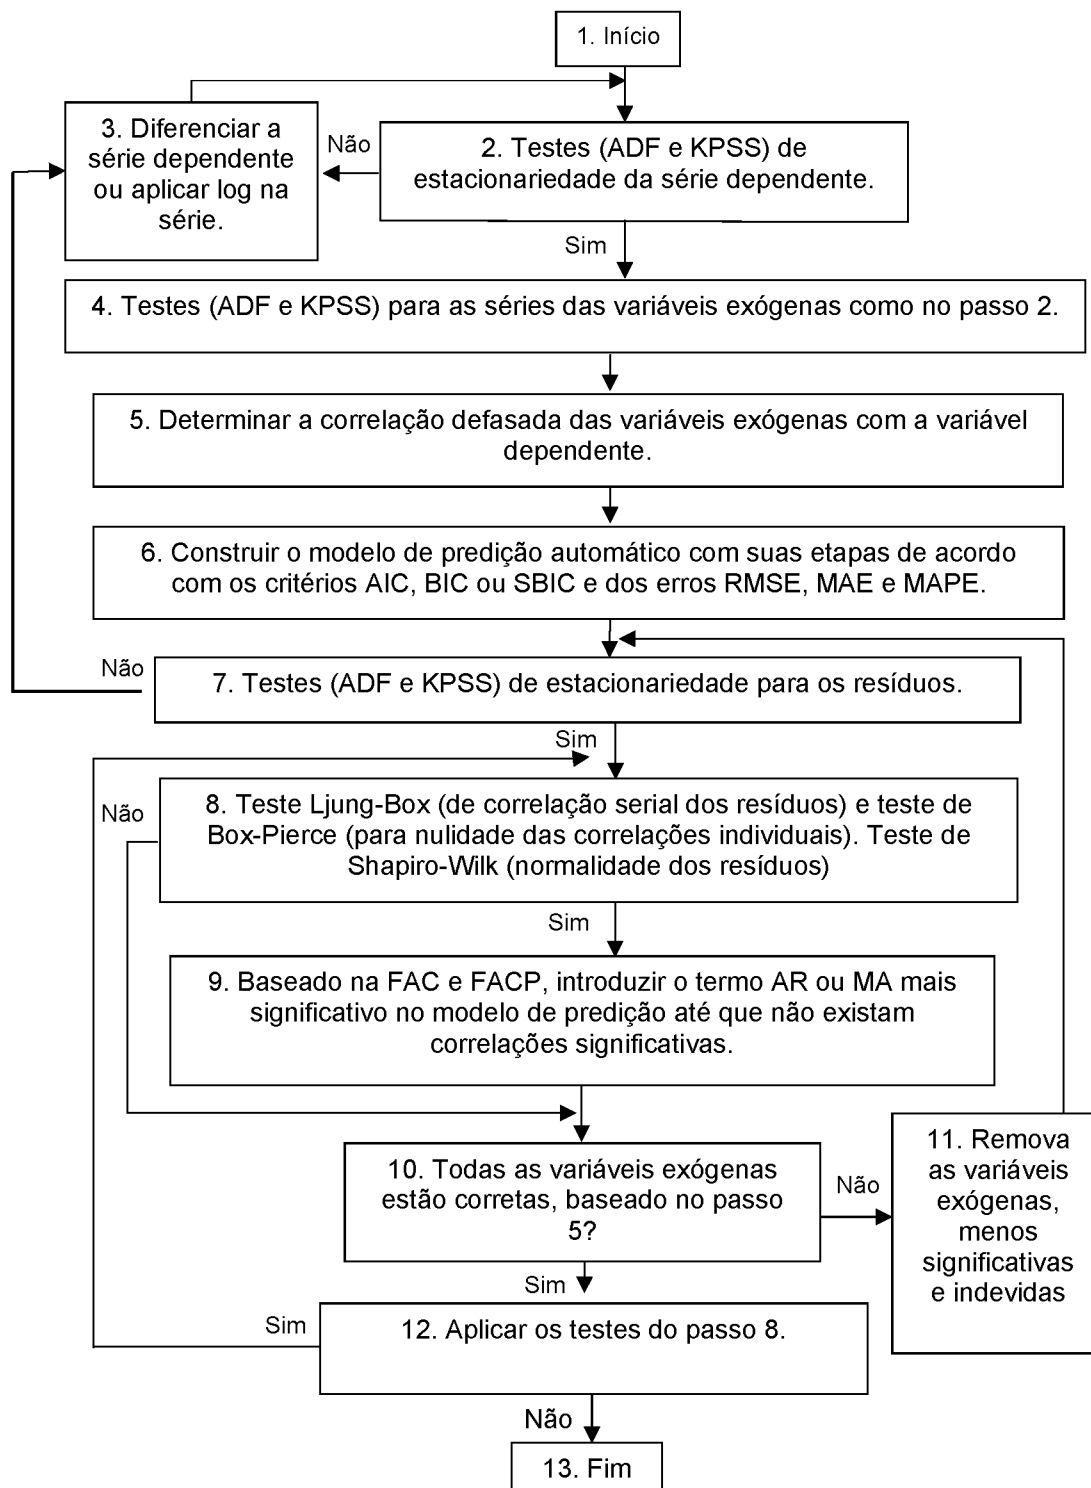
Em que, β são os coeficientes das variáveis exógenas X_r . Se considerar o efeito sazonal, o modelo (14) é dito $SARIMAX(p, d, q, r) \times (P, D, Q)_s$, definido por:

$$\phi(B)\Phi(B^s)(1-B^s)^D(1-B)^d Z_t = \delta + \theta(B)\Theta(B^s)a_t + \beta(1-B)^d X_r \quad (15)$$

A análise do impacto que as variáveis exógenas têm no modelo de predição é feita pela correlação destas variáveis com os resíduos das predições do modelo

ajustado, sendo que as variáveis exógenas também devem ser de uma série estacionária (BOX et al., 1994). A FIGURA 10 mostra os passos para determinação dos parâmetros de um modelo SARIMAX.

FIGURA 10 - FLUXOGRAMA DO MODELO SARIMAX



2.2.2 DECOMPOSIÇÃO DE UMA SÉRIE TEMPORAL

Conforme Morettin e Toloi (1981), uma série temporal pode ser decomposta em subséries, de acordo com o tipo de modelagem: Modelo aditivo ou modelo multiplicativo. No modelo aditivo, uma série temporal Z_t pode ser decomposta como segue:

$$Z_t = T + C + S + I \quad (16)$$

No modelo multiplicativo, tem-se:

$$Z_t = T \cdot C \cdot S \cdot I \quad (17)$$

Sendo, T – Tendência, C – Ciclo, S – Sazonalidade e I – Componente Aleatória.

A decomposição clássica de uma série temporal possibilita a pesquisa de aspectos específicos de interesse do pesquisador para fins de predição. Cada componente tem uma forma de ser decomposta, assim, pode-se dizer que:

- A curva de tendência (T) é obtida pelo método dos mínimos quadrados ordinários ou por médias móveis;
- A sazonalidade (S) é representada por índices sazonais, ou fatores sazonais, um para cada período do ano (se a série tem valores mensais há 12 índices, se tiver valores trimestrais há 4 índices e assim sucessivamente). Existem vários métodos para determinação dos índices sazonais, o mais comum é o método da razão para a média móvel (ou método da média móvel percentual);
- A componente aleatória (I) é obtida com a remoção das componentes de tendência e sazonalidade. Para o modelo multiplicativo, tem-se:

$$I = \frac{T \times S \times C}{Z_t}.$$

Outra técnica robusta que pode ser utilizada para decomposição de uma série temporal é a *Singular Spectrum Analysis* – SSA ou Análise Espectral Singular. É um método não paramétrico que consiste na decomposição e reconstrução de uma série temporal através de elementos de análise clássica de séries temporais, estatística multivariada, sistemas dinâmicos e processamento de sinais. Não exige o conhecimento prévio de características específicas da série temporal, tais como estacionariedade, normalidade ou oriundas de processos lineares e não lineares (GOLYANDINA et al., 2001). O objetivo do método é decompor a série temporal em

vários componentes aditivos independentes, que podem ser interpretados como componente de tendência, componentes oscilatórios (ciclo e sazonalidade) e componentes de ruído (GOLYANDINA et al., 2001; HASSANI, 2007; CASSIANO, 2014).

A análise básica de uma série temporal por SSA consiste em dois estágios complementares e cada estágio tem duas fases, conforme Golyandina et al. (2001): no estágio 1 tem a decomposição da série temporal com as fases de incorporação (*embedding*) e decomposição de valor singular – SVD (*Singular Value Decomposition*); no estágio 2 tem a reconstrução da série temporal com as fases de agrupamento (*grouping*) e reconstrução da série temporal via média diagonal (*diagonal averaging*).

Estágio 1 – Decomposição da série temporal

A série temporal original é decomposta em uma soma de subséries, de forma que cada subsérie possa ser identificada e interpretada de forma independente. Na *primeira fase* a incorporação é um procedimento no qual a partir de uma série temporal unidimensional real e não nula (com pelo menos um valor diferente de zero) $Z_t = [z_t]_{t=1}^N$, em que N é o tamanho da série ou a quantidade de observações ao longo do intervalo investigado, a série original é transformada através de um mapa $F: \mathbb{R}^N \rightarrow \mathbb{R}^{L \times K}$, em uma série multidimensional por uma matriz não singular de Hankel, denominada **matriz trajetória**, definida por $Y = [Y_1, \dots, Y_K]_{L \times K} \in \mathbb{R}^{L \times K}$, em que $Y_j = [z_1, \dots, z_{j+L-1}]^N \in \mathbb{R}^L$, $j = 1, \dots, K$. Isto é, $Z_t \in \mathbb{R}^N \xrightarrow{F} Y \in \mathbb{R}^{L \times K}$, em que $K = N - L + 1$ e

$$Y = F(Z_t) = [Y_1, \dots, Y_K]_{L \times K} = (x_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} z_1 & z_2 & z_3 & \dots & z_K \\ z_2 & z_3 & z_4 & \dots & z_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ z_L & z_{L+1} & z_{L+2} & \dots & z_N \end{bmatrix} \quad (18)$$

K é o número de vetores ou subséries defasadas no tempo. L é o único parâmetro nesta fase e deve ser um valor inteiro, suficientemente grande, entre $2 \leq L \leq N$, mas não superior a $\frac{N}{2}$ (HASSANI, 2007).

Na *segunda fase* é realizada a decomposição da matriz trajetória Y por SVD em uma soma de matrizes elementares de posto 1 e de acordo com Kubrusly (2001), Y é uma matriz semidefinida positiva. Seja S a matriz produto de Y com sua transposta, ou seja, $S = Y \cdot Y'$, com $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ os autovalores de S e U_1, \dots, U_L os autovetores correspondentes associados aos respectivos autovalores, de modo que os autovetores formam uma base ortonormal do espaço coluna de Y que é denominado **espaço trajetória** (GOLYANDINA, 2010). Desta forma, a matriz trajetória Y pode ser expandida através da decomposição de seus valores singulares (SVD) por:

$$Y = E_1 + E_2 + \dots + E_d \quad (19)$$

Em que:

$E_i = \sqrt{\lambda_i} \cdot U_i \cdot V_i'$, $i = 1, \dots, d$ são denominadas matrizes elementares;

$V_i = \frac{Y' \cdot U_i}{\sqrt{\lambda_i}}$, $i = 1, \dots, d$ são os autovetores normalizados ou componentes principais

da matriz trajetória Y e d é o número de autovalores não nulos da matriz S ou posto de S ;

$\sqrt{\lambda_i}$, $i = 1, \dots, d$ são os valores singulares de Y e o conjunto $\{\sqrt{\lambda_i}\}_{i=1}^d$ é denominado **espectro singular** de Y .

Estágio 2 – Reconstrução da série temporal

A reconstrução de uma série temporal menos ruidosa é realizada a partir da decomposição da matriz trajetória Y , feita na segunda fase do estágio 1 por SVD, tem duas fases: *agrupamento* e *média diagonal*. A *fase de agrupamento* consiste em agrupar as matrizes elementares E_i em vários grupos e realizar a soma delas dentro de cada grupo. O conjunto de índices da equação (19) é particionado em subconjuntos disjuntos e agrupado através de algum método de agrupamento, por exemplo, análise de componentes principais, análise de agrupamentos por clusterização hierárquica integrada com análise de componentes principais ou análise gráfica de vetores singulares. Assumindo que, após o agrupamento o conjunto de índices gerado é dado por $I = \{i_1, i_2, \dots, i_p\}$ então, a matriz E_I correspondente ao grupo I é definida como $E_I = E_{i_1} + E_{i_2} + \dots + E_{i_p}$ em subconjuntos

disjuntos $I = \{I_1, \dots, I_m\}$ em que $m \leq d$. Assim, a matriz trajetória Y , da equação (19), pode ser reescrita como:

$$Y = \sum_{i=1}^m E_{I_i} = E_{I_1} + E_{I_2} + \dots + E_{I_m} \quad (20)$$

A *média diagonal* é utilizada na última fase do segundo estágio da reconstrução da série temporal, com o objetivo de transformar uma matriz de Hankel em uma série temporal que é um componente aditivo da série original. Seja Y a matriz trajetória e assumindo que $L^* = \min\{L, K\}$ e que $K^* = \max\{L, K\}$, considere também que $y_{l,k}^{(i)}$ seja um elemento da linha l e coluna k da matriz E_{I_i} . O elemento $z_t^{(i)}$ da componente SSA $\left[z_t^{(i)} \right]_{1 \times N}$ é calculado através da média diagonal, a partir de E_{I_i} por:

$$\tilde{z}_t^{(i)} = \begin{cases} \frac{1}{t} \cdot \sum_{l=1}^t y_{l,t-l+1}^{(i)}, & \text{se } 1 \leq t < L^* \\ \frac{1}{L^*} \cdot \sum_{l=1}^{L^*} y_{l,t-l+1}^{(i)}, & \text{se } L^* \leq t < K^* \\ \frac{1}{N-K^*+1} \cdot \sum_{l=t-K^*+1}^{N-K^*+1} y_{l,t-l+1}^{(i)}, & \text{se } K^* \leq t \leq N \end{cases} \quad (21)$$

Este processo equivale à decomposição da série temporal original $Z_t = [z_t]_{t=1}^N$ em uma soma de m séries tais que:


$$z_t = \sum_{i=1}^m \tilde{z}_t^{(i)} \quad (22)$$

e conforme Golyandina et al. (2001), as componentes SSA $\left[z_t^{(i)} \right]_{1 \times N}$ podem ser classificadas em três categorias que são: *tendência*, *componentes harmônicas* (ciclo e sazonalidade) e *ruído*. Neste trabalho, a aplicação da técnica SSA é específica para identificar a tendência da série temporal.

Nem toda a série temporal tem todas as componentes descritas nas equações (16) e (17), algumas séries temporais não têm tendência ou ciclo ou sazonalidade. O processo de decomposição permite identificar estas componentes numa determinada série temporal para otimizar a modelagem. A FIGURA 1 mostra

uma curva de deformação por fluência em diferentes tempos e a FIGURA 11 mostra a decomposição de uma série temporal, pelo modelo multiplicativo, nas componentes de tendência, sazonalidade e componente aleatória.

FIGURA 11 - DECOMPOSIÇÃO DE UMA SÉRIE TEMPORAL E AS COMPONENTES DE TENDÊNCIA, SAZONALIDADE E COMPONENTE ALEATÓRIA

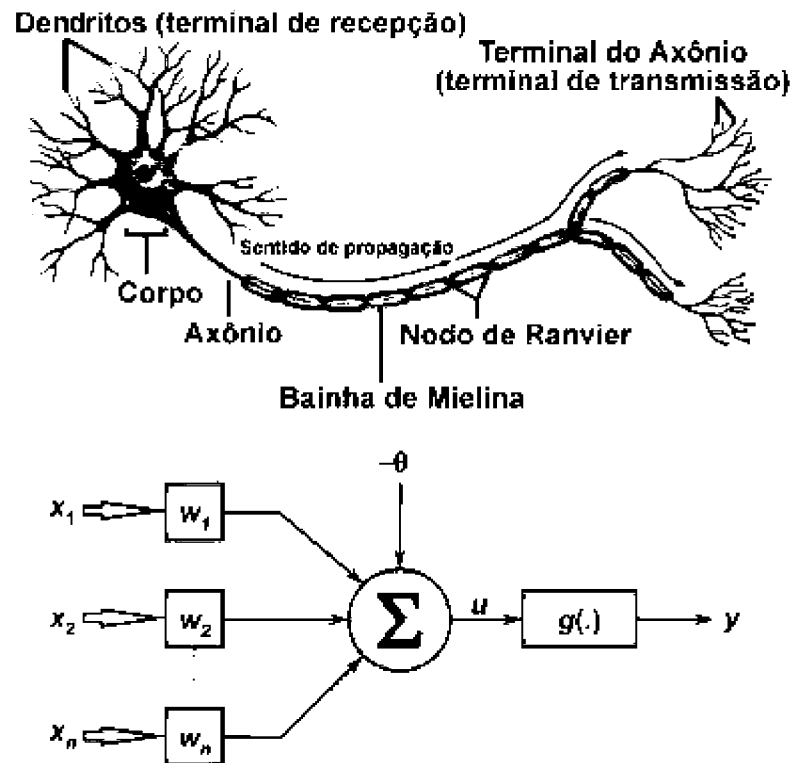


FONTE: Itaipu (2017)

2.2.3 METODOLOGIA DE REDES NEURAIS ARTIFICIAIS (RNAs)

As pesquisas sobre Redes Neurais Artificiais (RNAs) surgiram com os primeiros estudos e trabalhos apresentados em 1943 por McCulloch-Pitts (MCCULLOCH e PITTS, 1990). Baseada no funcionamento dos neurônios humanos, a ideia era muito básica e intuitiva e não apresentava um algoritmo com capacidade de aprendizagem para a rede neural. Uma ilustração de um neurônio biológico humano associado a uma rede neural artificial é mostrado na FIGURA 12.

FIGURA 12 - REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO HUMANO E UMA REDE NEURAL CORRESPONDENTE



FONTE: Monolitonimbus (2018)

De acordo com Tafner (1996), um neurônio biológico é constituído por: um *corpo* celular (ou soma), onde está contido o núcleo da célula; os *dendritos*, por onde são recebidos os impulsos elétricos e um *axônio*, por meio do qual os impulsos elétricos são enviados a outro neurônio. A interligação entre um neurônio e o outro é feita por *sinapse* (ponto de contato controlado por impulso elétrico e por reação química), formando assim, uma rede neural de transmissão de informações.

Conforme Haykin (2001), um neurônio artificial é composto pelos seguintes elementos: pesos sinápticos, somador e função de ativação.

- i) Os *pesos sinápticos* formam um conjunto de coeficientes $\left\{ \left\{ W_{kt} \right\}_{k=1}^K \right\}_{t=1}^N$, em que, W_{kt} denota o peso sináptico associado ao padrão de entrada x_t pertencente ao conjunto de entrada $\{x_t\}_{t=1}^T$ (observado o instante t) e ao k -ésimo neurônio artificial, para todo $t \in \{1, \dots, N\}$ e para todo $k \in \{1, \dots, K\}$;

- ii) Um *somador* consiste num operador Σ , para efetuar a operação de soma dos produtos dos pesos sinápticos W_{kt} pelos respectivos

padrões de entrada x_t . Isto é, uma combinação linear $\sum_{t=1}^n (W_{kt}x_t) + b_k$,

sendo b_k o intercepto (ou nível, ou *bias*), que tem a função de aumentar ou diminuir a entrada da função de ativação, podendo, assim, ser positivo ou negativo. Conforme Haykin (2001), a soma ponderada

$\sum_{t=1}^n (W_{kt}x_t) + b_k$ pode ser dita *regra de propagação*;

- iii) A *função de ativação* (h), de um neurônio artificial, é utilizada como restrição da amplitude de saída (y_k). Seja a regra de propagação

$\sum_{t=1}^n (W_{kt}x_t) + b_k = u_k$, tem-se a saída $y_k = h(u_k)$, em que $k \in \{1, \dots, K\}$.

Vários algoritmos foram desenvolvidos com o objetivo de treinar uma rede neural. Destaca-se o algoritmo *perceptron*, Rosenblatt (1958), com uma única camada escondida, para problemas não lineares separáveis. Kohonen (1982), publicou os mapas auto organizáveis, e Rumelhart et al. (1986), publicaram no livro *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, o algoritmo de treinamento por retro propagação denominado *backpropagation*, proposto por Werbos (1974), que se tornou o algoritmo de aprendizagem mais utilizado nos modelos de RNAs multicamadas *Multilayer Perceptron* (MLP).

Outro importante avanço nas pesquisas e aplicações de RNAs foi quando Mulgrew (1996), publicou um trabalho sobre redes neurais artificiais, particularmente adequadas à aproximação de funções, denominada *funções de base radial* (*Radial Basis Function* – *RBF*).

As redes MLP tendem a produzir aproximações globais, enquanto que as redes RBF tendem a resultar em aproximações locais, porém ambas as redes neurais são aproximadoras universais. As principais diferenças entre as redes neurais *MLP* e *RBF* de acordo com Haykin (2001), estão relacionadas na TABELA 5:

TABELA 5 - COMPARAÇÃO DE ESTRUTURAS ENTRE AS REDES NEURAIS MLP E RBF

Rede neural do tipo MLP	Rede neural do tipo RBF
<ul style="list-style-type: none"> - Tem uma ou mais camadas ocultas - Na camada oculta as funções de ativação são funções sigmóides ou tangente hiperbólica - A camada oculta e a camada de saída são não lineares (em classificação de padrões). Em problemas de regressão não linear, a camada oculta é não linear e a camada de saída é linear - A função de ativação calcula o produto interno do vetor de entrada pelo vetor de pesos sinápticos de cada unidade oculta - Produzem aproximações globais - Requer menor número de parâmetros para mesmo grau de precisão 	<ul style="list-style-type: none"> - Tem uma única camada oculta - Na camada oculta as funções de ativação são funções de base radial - A camada oculta é não linear e a camada de saída é linear e tem menor erro como classificador de padrões - O argumento da função de ativação da unidade oculta calcula a norma (euclidiana) entre o vetor de entrada e o centro daquela unidade - Constroem aproximações locais e globais - Tem menor tempo de ajuste na camada oculta

FONTE: Haykin (2001)

Na década de 1980 dois pesquisadores A. J. Robinson e F. Fallside apresentaram trabalhos importantes e foram precursores nas pesquisas sobre redes neurais recorrentes ou *Recurrent Neural Network (RNN)*. As principais características deste tipo de rede neural são a interações entre os neurônios da camada oculta que possibilita o treinamento e predição de séries temporais de processos de alta complexidade, obtendo melhor acurácia em relação aos tipos de redes tradicionais *MLP* e *RBF* (ROBINSON e FALLSIDE, 1987).

2.2.3.1 REDES NEURAIS RECORRENTES

As pesquisas sobre redes neurais recorrentes *Recurrent Neural Network (RNN)* foram desenvolvidas a partir dos trabalhos de (ROBINSON e FALLSIDE, 1987; RUMELHART et al., 1986). Por ser uma classe de redes neurais que inclui conexões ponderadas dentro de uma camada oculta, formando loops que podem armazenar informações ao processar novas entradas, as *RNNs* Deep Learning com arquitetura *LSTM* criam uma memória interna longa de curto prazo em que as entradas anteriores são consideradas como dados da própria série temporal HOCHREITER e SCHMIDHUBER (1997). Em comparação com as

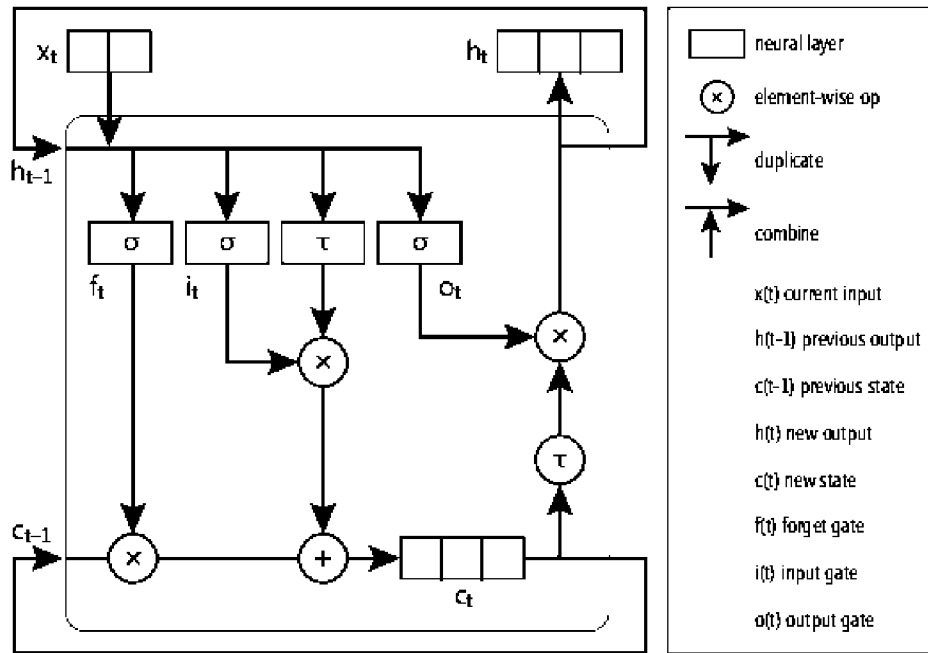
redes de *feed-forward* tradicionais *MLP* e *RBF*, em que a rede é alimentada apenas para camadas subsequentes, essa memória se torna importante para executar tarefas de processamento de alta complexidade.

Nas redes neurais unidirecionais ou pró-alimentadas chamadas *Feed-forward neural network*, há somente um caminho a percorrer: da entrada para a saída. Não há feedback (*loops*), ou seja, a saída de qualquer camada oculta não afeta a mesma camada. Já nas redes neurais recorrentes ou retroalimentadas podem ter sinais sinápticos viajando em ambas as direções, introduzindo *loops* na rede. As computações derivadas da entrada anterior são realimentadas na rede, o que lhes dá um tipo de “memória curta”. Seu “estado” muda continuamente até atingir um ponto de equilíbrio, permanecendo nele até que o input mude e um novo equilíbrio seja encontrado (SCHMIDHUBER, 2014).

O efeito prático disso é a existência de memória de curto prazo na rede, mas por um longo período de tempo. Considerando o aprendizado por treinamento uma espécie de memória de longo prazo, então, as redes neurais recorrentes podem criar modelos muito mais complexos, capazes de resolver uma gama maior de problemas (BENGIO, 2009).

É importante destacar que as redes neurais *Deep Learning* com arquitetura *LSTM* são indicadas para predição de séries temporais sequenciais GRAVES (2012). A FIGURA 13 mostra a arquitetura de uma rede neural recorrente *Deep Learning* com arquitetura *LSTM*.

FIGURA 13 - ARQUITETURA LSTM DE UMA REDE DEEP LEARNING



FONTE: MacCaffrey (2018)

Em que:

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (23)$$

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (24)$$

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (25)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tau(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (26)$$

$$h_t = o_t \cdot \tau(c_t) \quad (27)$$

Com:

- n é o tamanho do vetor de entrada
- m é o tamanho da célula de estado e de saída
- x_t é o vetor de entrada no instante t e tamanho $n \times 1$
- f_t vetor forget gate $m \times 1$
- i_t vetor portão de entrada (input gate) $m \times 1$
- o_t vetor portão de saída (output gate) $m \times 1$
- h_t vetor de saída (output) $m \times 1$
- c_t vetor cell state $m \times 1$
- W_f, W_i, W_o, W_c : pesos das matrizes do portão de entrada (input gate) $m \times n$
- U_f, U_i, U_o, U_c : pesos dos vetores do portão de saída (output gate) $m \times n$

- b_f, b_i, b_o, b_c : vetores bias $m \times 1$
- σ função de ativação sigmoide logística
- τ função de ativação tgh (tangente hiperbólica)

As equações (23), (24) e (25) definem, respectivamente, três portões (*gates*): um portão de entrada; um portão de esquecimento que identifica quais informações devem ser descartadas por meio de ajuste de pesos e um portão de saída. Cada portão é um vetor de valores entre 0 e 1, usados para determinar o quanto da informação será esquecida ou, de forma equivalente, lembrada em cada ciclo de entrada-saída. A equação (26) calcula o novo estado (*state*) da célula e a equação (27) calcula a nova saída (HOCHREITER e SCHMIDHUBER, 1997).

2.2.4 COMBINAÇÃO DE MÉTODOS DE PREDIÇÃO

A combinação de métodos de predição (denominada de métodos híbridos) de séries temporais teve início com os primeiros trabalhos de Bates e Granger (1969), que consiste na combinação linear de modelos individuais. Para o caso de uma combinação de predição, de uma série temporal $\{z_t\}_{t=1}^N$, de dois métodos individuais, tem-se:

$$\hat{z}_t = \rho_1 \hat{z}_{1,t} + (1 - \rho_1) \hat{z}_{2,t} \quad (28)$$

Em que $0 < \rho_1 < 1$ é o coeficiente (peso), obtido a partir da variância dos erros das previsões individuais, correspondentes aos respectivos métodos individuais $\hat{z}_{1,t}$ e $\hat{z}_{2,t}$ (método 1 e método 2, respectivamente).

Granger e Ramanathan (1984) propuseram uma alteração no trabalho de Bates e Granger (1969), introduzindo uma constante de forma que a predição seja não viesada, eliminando assim, a condição de que $0 < \rho_1 < 1$. No trabalho de Gupta e Wilton (1987) foi proposto a utilização da média aritmética simples, para obtenção dos pesos, dos métodos individuais na combinação de predição do modelo híbrido. Teixeira Júnior (2013) utilizou a programação matemática para determinar os valores dos pesos, dos coeficientes dos modelos individuais, a partir da resolução de um

problema de programação não linear, sendo a função objetivo composta pela soma dos erros quadráticos de predição dos modelos individuais.

É importante destacar que o termo *combinação de métodos preditivos individuais* pode ser utilizado em sentido amplo e se referir tanto a abordagem de combinações de previsões Makridakis e Winkler (1983), quanto à combinação de densidades preditivas bayesianas (FARIA e MUBWANDARIKWA, 2008). Nesta pesquisa é utilizado apenas como combinação de predições.

De acordo com Granger (1989), a combinação de predições pode aumentar a acurácia das predições e, Clemen (1989) salienta que ao invés de escolher o melhor modelo individual, o problema passa a ser de quais modelos combinados podem melhorar a acurácia das predições, além de agregar informações distintas oriundas dos modelos individuais, sobre a flutuação estocástica da série temporal a ser modelada.

Wallis (2011) apresenta uma revisão histórica abordando um período de 42 anos de pesquisa relacionada aos modelos híbridos (combinação de métodos individuais) atestando a eficiência da acurácia, além de mostrar uma vasta abordagem de aplicações e abordagens. Faria e Mubwandarikwa (2008), indicam duas maneiras de se determinar um método híbrido preditivo gerador de previsões:

- i) Escolhe-se um modelo preditivo dentre os $\{\Omega_m\}_{m=1}^N$ modelos, baseado em algum critério de seleção;
- ii) Escolhe-se K modelos preditivos, dentre os $\{\Omega_m\}_{m=1}^N$ modelos (com $K < N$) para combiná-los, de forma linear ou não linear.

De forma resumida conforme (Faria e Mubwandarikwa, 2008; Teixeira Júnior, 2013; Rodrigues, 2015), pode-se representar a forma de predição de uma metodologia híbrida, de combinação linear, em duas etapas:

- a) A partir de um conjunto E^K de todas as previsões, dentro e fora da amostra, oriundas dos K modelos preditivos individuais escolhidos, pelo modelador, dentre os $\{\Omega_m\}_{m=1}^N$ modelos preditivos, com $K < N$;

- b) Obter o conjunto de combinação $\hat{z}_{CL} : \begin{cases} E^K \rightarrow \mathbb{R} \\ [\hat{z}_k(t)]_{k=1}^K \in E^K \rightarrow \hat{z}_{CL}(t) \in \mathbb{R} \end{cases}$ de previsões (geral) que transforma um vetor $[\hat{z}_k(t)]_{k=1}^K \in E^K$ de previsões

em uma predição combinada $\hat{z}_{CL}(t) = \sum_{k=1}^K (\rho_k \cdot \hat{z}_k(t)) + \alpha$ para todo $t = 1, 2, \dots, t+h$.

Em que h é o horizonte de predição; $\hat{z}_{CL}(t)$ é a predição combinada linearmente; $\hat{z}_k(t)$ é a predição do k -ésimo modelo-base; ρ_k é o k -ésimo peso adaptativo associado linearmente a predição $\hat{z}_k(t)$ e α é a constante aditiva adaptativa.

Em Zhang (2003) foi proposto um método híbrido, combinando os modelos ARIMA (da metodologia Box & Jenkins) e redes neurais *MLP*. A modelagem foi realizada em duas etapas: Na primeira etapa, nos modelos ARIMA, a modelagem foi para representar a estrutura linear dos dados observados e, na segunda etapa (aplicada aos resíduos gerados a partir da modelagem ARIMA), a modelagem por redes neurais *Multilayer perceptron (MLP)*, para representar a estrutura não linear dos referidos dados de treinamento. Zheng e Zhong (2011) propuseram um modelo híbrido, combinando os modelos AR e redes neurais *RBF*, baseado em suavização binomial. No entanto, sua proposta tem ordem inversa na aplicação dos métodos, ou seja, primeiro foi realizada a modelagem via redes neurais *RBF* nos dados de treinamento (modelando a estrutura não linear). Em seguida foi aplicado os modelos autorregressivos *AR(p)*, nos resíduos gerados a partir da modelagem por redes neurais *RBF* (para modelar a estrutura linear dos dados de treinamento). A equação (29) representa a modelagem híbrida para uma série temporal $\{z_t\}_{t=1}^N$:

$$[z_t]_{t=1}^N = [L(t)]_{t=1}^N + [NL(t)]_{t=1}^N \quad (29)$$

Em que $[L(t)]_{t=1}^N$ é denominada componente linear e $[NL(t)]_{t=1}^N$ é a componente não linear correspondente à série temporal $\{z_t\}_{t=1}^N$.

É importante destacar que o método híbrido ARIMA-ANN desenvolvido por Zhang Zhang (2003), em que a modelagem é realizada primeiramente pelo modelo ARIMA e nos resíduos deste é realizada a modelagem por redes neurais *MLP*, para obter a predição final que é uma combinação linear das predições individuais. Zheng e Zhong (2011) apresentaram um método híbrido ANN-ARIMA em que na primeira etapa é realizada por redes neurais *RBF* para estimar a componente não linear da predição e a segunda etapa é aplicada a modelagem ARIMA nos resíduos da redes

neurais. Ambos do métodos híbridos Zhang (2003), Zheng e Zhong (2011) são aplicáveis às séries temporais sem variáveis exógenas e não sazonais.

Aburto e Weber (2007) apresentaram um método híbrido, dos modelos SARIMA e redes neurais *MLP* para séries temporais sazonais, aplicado à previsão de demanda de produtos de um supermercado no Chile, porém, a série original foi composta, segundo os autores, por uma combinação de várias séries de produtos sem especificar as variáveis exógenas. Em Babu e Reddy (2014) foi apresentado um método híbrido composto pelos modelos ARIMA e redes neurais *MLP* e utilizado um filtro de médias móveis na pré-modelagem para identificar a volatilidade da série temporal através da curtose.

2.2.5 BOOTSTRAP

O método *Bootstrap* é um procedimento estatístico não-paramétrico, apresentado por Efron (1979), cujo principal objetivo é a reamostragem dos dados originais, com reposição, para obter novos conjuntos de dados que possibilita estimar uma média de interesse.

Se o conjunto de dados em análise segue uma distribuição normal, então, o *Teorema Central do Limite* é utilizado para determinar um intervalo de confiança para a variabilidade deste conjunto de dados, porém, se a quantidade de dados é insuficiente ou os dados não seguem uma distribuição normal, o método *Bootstrap* é utilizado para reamostragem dos dados e assim, obter uma distribuição apropriada para determinar o intervalo de variabilidade destes dados (DAVISON e HINKLEY, 1997).

Seja uma amostra aleatória $Y = (y(1), y(2), \dots, y(t))$ de uma distribuição F desconhecida e seja $\hat{\theta} = s(Y)$ o estimador do parâmetro θ desta distribuição. O método *Bootstrap* gera um número B de amostras $y_1(t), y_2(t), \dots, y_B(t)$, denominadas amostras *Bootstrap*, que são independentes da distribuição empírica \hat{F} e permitem calcular o estimador *Bootstrap* do parâmetro de interesse (por exemplo média e/ou erro padrão) $\hat{\theta}_b = s(y_b(t))$ com $b = 1, 2, \dots, B$ para cada uma das amostras. De acordo com Efron e Tibshirani (1994), as B amostras *Bootstrap* são utilizadas para estimar a verdadeira distribuição de probabilidade desconhecida, assim como,

intervalos de confiança. O erro padrão do estimador *Bootstrap* $\hat{\theta}$ pode ser determinado por:

$$\widehat{se}_{boot}(\hat{\theta}) = \sqrt{\frac{1}{B-1} \sum_{b=1}^B \left(\hat{\theta}_b - \frac{1}{B} \sum_{b=1}^B \hat{\theta}_b \right)^2} \quad (30)$$

Em que $\bar{\theta}_b = \frac{1}{B} \sum_{b=1}^B \hat{\theta}_b$ é a média do estimador.

Em suas aplicações, no contexto das regressões, Tibshirani (1996) utilizou entre 20 e 200 amostras *Bootstrap* e sugere dois tipos de amostragem *Bootstrap* para determinar os intervalos de confiança: *Bootstrap pairs* e *Bootstrap residual*.

No *Bootstrap pairs* é considerado o conjunto dos dados originais que são amostrados, cada um deles com a mesma probabilidade de ser selecionado, e substituídos no conjunto original.

Para o *Bootstrap residual* é necessário um modelo de regressão ajustado sobre o conjunto dos dados originais e o cálculo dos respectivos resíduos. Assim, os resíduos são reamostrados e novas séries sintéticas são geradas.

Neste trabalho foi utilizado o *Bootstrap residual* para obtenção dos intervalos de confiança, pois, a reamostragem foi feita a partir dos resíduos do método híbrido SARIMAX-NEURAL. Segue um resumo do algoritmo *Bootstrap residual*, de acordo com TIBSHIRANI (1996).

Considere a série temporal $[Y]_{t=1}^N = (y(1), y(2), \dots, y(t))$ com $t = 1, 2, \dots, N', N'+1, \dots, N$ valores da amostra original, o algoritmo *Bootstrap residual* consiste em:

- Obter o modelo ajustado para $[\hat{y}(t)]_{t=N'}^N$, referente aos dados originais $[Y]_{t=1}^N$ em que N' indica os graus de liberdade não considerados;
- Calcular os resíduos do modelo ajustado $[r_b(t)]_{t=N'}^N = (y(t))_{t=N'}^N - (\hat{y}(t))_{t=N'}^N$;
- Gerar as B amostras *Bootstrap* $[r_b(t)]_{t=N'}^N$, cada uma de tamanho $N - N'$;
- Criar as novas séries sintéticas $[y_b(t)]_{t=N'}^N = (\hat{y}(t) + r_b(t))_{t=N'}^N$;
- Para cada série sintética obter as previsões $[\hat{y}_b(t)]_{t=N}^{N+h}$;

f) Estimar o erro padrão do t -ésimo valor predito por

$$\sqrt{\frac{1}{B-1} \sum_{b=1}^B (\hat{y}_b(t) - \bar{\hat{y}}_b)^2}, \text{ em que } \bar{\hat{y}}_b = \frac{1}{B} \sum_{b=1}^B \hat{y}_b(t).$$

2.2.6 INTERVALOS DE CONFIANÇA

De acordo com Pan e Politis (2016), os intervalos de confiança (IC) para predições são utilizados, em modelos de regressão, com o objetivo de estimar os parâmetros do modelo e adicionar informações de incertezas referentes as estimativas pontuais das predições.

Sejam os dados de entrada e saída $(x(t), y(t))_{t=1}^N$, respectivamente, com o modelo de regressão proposto da forma $y(x) = f(x, w) + e(x)$ onde $y(x)$ são os alvos, w são os parâmetros verdadeiros do modelo desconhecido $f(x, w)$ e $e(x)$ é o ruído com média zero. Considere \hat{w} os estimadores de w e $k(x, w)$ que pode ser considerada como a média dos alvos y e x para função $f(x, w)$.

De acordo como Khosravi et al. (2015), variância $\sigma_k^2(x)$ indica a incerteza do modelo de regressão e está associada à aproximação $k(x, w)$ de $f(x, w)$. Os autores aplicaram *Bootstrap* para determinar os IC, em redes neurais, por meio da equação:

$$m(x) - t_{1-\frac{\alpha}{2}, gl} \sigma_k(x) \leq f(x, w) \leq m(x) + t_{1-\frac{\alpha}{2}, gl} \sigma_k(x) \quad (31)$$

Em que o valor $t_{1-\frac{\alpha}{2}, gl}$ advém da distribuição *t-Student* com nível de significância α ,

gl é o número de graus de liberdade, definido neste trabalho pela diferença entre o número h de predição fora da amostra de treinamento e o número de parâmetros do

modelo ajustado e $m(x_b) = \frac{1}{B} \sum_{b=1}^B k(x_b, \hat{w})$.

Mais detalhes sobre este o método *Bootstrap* e intervalos de confiança podem ser encontrados nos trabalhos de DAVISON e HINKLEY (1997) e EFRON e TIBSHIRANI (1994).

3 MATERIAIS E MÉTODOS

A Itaipu disponibilizou para realização desta pesquisa os dados históricos das deformações corrigidas do concreto e da temperatura ambiente, medidos por rosetas de deformímetro instaladas no bloco de contraforte D57 e também a série histórica da temperatura ambiente.

Uma vez que os dados não representavam uma série temporal originalmente, por questões de inconsistência na escala de tempo padrão, foi necessário um ajuste (na distribuição dos dados) para torná-las em séries temporais cronologicamente padronizadas. Neste trabalho foi usada a interpolação *Spline cúbica*, pois, dentre as curvas *Spline* a que *Spline cúbica* tem menor erro na interpolação, Lutterkort e Peters (1999), para padronizar cronologicamente as séries originais, transformando os dados históricos originais em séries temporais semanais. A técnica de interpolação por *Spline cúbica* consiste em interpolar (por partes) polinômios de grau 3 num conjunto de pontos $[x_0, x_n]$, sendo $x_0 < x_1 < x_2 < \dots < x_n$ com nós de interpolação em cada subintervalo $[x_i, x_{i+1}]$, $i = 0, 1, 2, \dots, (n-1)$ (RUGGIERO e LOPES, 1998). Esta tem sido uma das técnicas não paramétricas mais aplicadas nos problemas de interpolação para complementação de dados (HAZEWINKEL, 2001). A interpolação por *Spline cúbica* utilizada neste trabalho, para padronização de todas as séries históricas, foi implementada no software *Maple 2016*.

É importante destacar o ajuste prévio dos dados históricos, como uma contribuição importante, deste trabalho de pesquisa, pois, a não padronização dos dados históricos (no tempo) pode gerar previsões distorcidas com defasagens de tempo diferentes. Por exemplo, se os dados históricos forem medidos em diferentes escalas de tempo (uma parte em horas, outra em dias, outra em semanas ou meses), não será possível determinar qual a escala de tempo das previsões, já que não seguem um padrão.

O ajuste prévio (de padronização da ordem cronológica dos dados) também foi aplicado nos dados históricos da temperatura ambiente, que nesta pesquisa será utilizada como variável exógena, nos modelos preditivos descritos nesta pesquisa.

Outro aspecto importante a se destacar nesta pesquisa, aplicado na pré-modelagem, é a identificação da correlação linear defasada entre as variáveis

exógena e endógena, isto é, entre a temperatura ambiente e a deformação diferida do concreto, respectivamente. A temperatura ambiente tem influência sobre as deformações corrigidas do concreto, porém, em períodos de tempos diferentes. Esta diferença de tempo é devido a geometria (dimensões) do bloco de concreto e também da incidência solar (coeficiente de difusividade térmica) sobre o bloco de concreto, por isso, foi realizada a correlação linear defasada, da série temporal das deformações corrigidas do concreto com a série temporal da temperatura ambiente.

Esta correlação linear defasada é medida pelo coeficiente linear de Pearson, Stanton e Jeffrey (2001), que varia no intervalo $[-1, 1]$ em que os extremos do intervalo indicam a máxima correlação e o índice 0 (zero) indica que não há correlação linear entre as variáveis. Se o coeficiente for negativo significa que as variáveis estão correlacionadas numa proporção inversa, enquanto que, o coeficiente positivo significa que a correlação linear é diretamente proporcional entre as variáveis.

Na determinação da correlação linear defasada foram utilizados os softwares *Microsoft Excel* e software *R*. Para a roseta RD-D09-5 (corresponde ao braço 5) do bloco de contraforte D57, a maior correlação foi obtida na sexta semana cujo índice de correlação foi 0,4037, ou seja, a temperatura ambiente, no tempo t , influenciou nas referidas deformações do concreto seis semanas depois (no tempo $t+6$). Para cada conjunto de dados, de cada roseta, foi feito o cálculo da correlação defasada, pois, as rosetas foram instaladas em diferentes pontos do bloco de concreto, conforme a FIGURA 9.

3.1 MÉTODO PROPOSTO

Neste trabalho é proposto um método híbrido denominado SARIMAX-NEURAL para prever as deformações corrigidas do concreto influenciadas pela temperatura ambiente a partir de séries temporais. Com a disponibilidade de dados históricos das deformações corrigidas do concreto da temperatura ambiente, fornecidos pela hidrelétrica de Itaipu, foram utilizadas as metodologias Box & Jenkins e RNN DL-LSTM para a predição de séries temporais univariadas (série das deformações corrigidas do concreto, como variável

dependente ou endógena, influenciada pela série temporal exógena da temperatura ambiente).

Pesquisas sobre as deformações corrigidas do concreto por meio de séries temporais não foram encontradas na literatura atual, tornando assim, a proposta desta tese inovadora e inédita como pesquisa das deformações corrigidas do concreto influenciadas pela temperatura ambiente.

O método híbrido SARIMAX-NEURAL proposto neste trabalho tem na fase de pré-modelagem a identificação da correlação defasada entre as séries temporais das deformações corrigidas do concreto (série da variável dependente) e da temperatura ambiente (série da variável exógena).

Este método híbrido é aplicável às séries temporais sazonais com variáveis exógenas e sua modelagem tem duas fases: na **primeira fase** é realizada a modelagem pelo modelo SARIMAX para prever a componente da parte linear da predição; na **segunda fase** é realizada a modelagem, na série dos resíduos do modelo SARIMAX, via redes neurais *Deep Learning* com arquitetura *LSTM* para prever a componente da parte não linear da predição.

Genericamente, as componentes preditivas linear e não linear, respectivamente, para uma série temporal $Z_t = \{z_t\}_{t=1}^N$ podem ser representadas por:

$$z_t = CL(t) + NL(t) \quad (32)$$

Assim, a predição do método híbrido é obtida como uma combinação linear (soma) da predição (das componentes linear e não linear) fora da amostra e representada por:

$$\hat{z}_f(t+h) = \widehat{CL}_f(t) + \widehat{NL}_f(t) \quad (33)$$

Em que $\widehat{CL}_f(t)$ é denominada componente linear da predição (fora da amostra de treinamento) e $\widehat{NL}_f(t)$ é a componente não linear correspondente à predição (fora da amostra de treinamento) da série temporal dos resíduos do método SARIMAX dentro da amostra que são representados por:

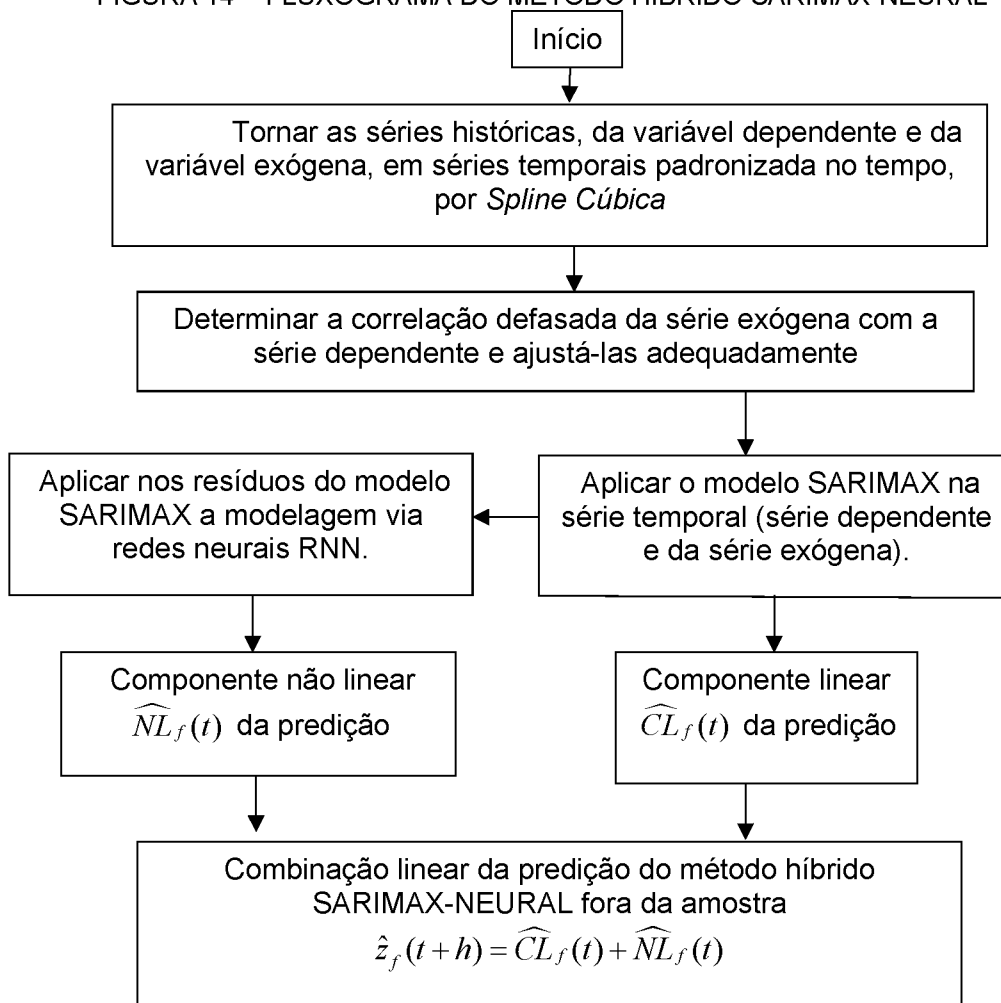
$$\hat{e}_a(t) = z_{ta} - \hat{z}_{ta} \quad (34)$$

Em que z_{ta} é o valor real e \hat{z}_{ta} é o valor previsto dentro da amostra. Assim, $\widehat{NL}_f(t)$ é a predição, por redes neurais *Deep Learning* com arquitetura *LSTM*, da série dos dados da equação (34), com o horizonte de predição $h = 52$ semanas à frente.

O algoritmo da rede neural *DL*, deste trabalho, é descrito pelo processamento das equações (23) até (27).

Na FIGURA 14 é mostrado o fluxograma do método híbrido SARIMAX-NEURAL proposto neste trabalho para a predição de séries temporais das deformações corrigidas do concreto influenciadas pela temperatura ambiente.

FIGURA 14 - FLUXOGRAMA DO MÉTODO HÍBRIDO SARIMAX-NEURAL



FONTE: o autor (2019)

3.2 ETAPAS DO MÉTODO

A partir da padronização dos dados históricos, pela interpolação *Spline cúbica* de Lutterkort e Peters (1999), transformando-os em uma série temporal padronizada semanalmente, foi realizada a modelagem pelo método SARIMAX (equação (15)) das deformações corrigidas do concreto e é composta das seguintes etapas:

ETAPA 1: Verificar se a série temporal é estacionária, aplicando os testes ADF e KPSS. Se não for estacionária, deve-se diferenciar a referida série temporal até torná-la estacionária. Esta verificação de estacionariedade também deve ser feita na série temporal da variável exógena (BOX e JENKINS, 1976).

O teste ADF (também conhecido como teste da raiz unitária) considera como hipótese nula (H_0), que a parte autorregressiva $AR(p)$, da série temporal seja não estacionária, isto é, que o polinômio $\phi(B)$ tenha raiz(es) unitária(s). Assim, tem-se que:

H_0 : Há raiz unitária (a série é não estacionária)

H_1 : Não raiz unitária (a série é estacionária)

O teste KPSS considera como hipótese nula (H_0) que a parte autorregressiva $AR(p)$, da série temporal é estacionária contra a hipótese alternativa (H_1) ser não estacionária. Segue-se que:

H_0 : a série é estacionária

H_1 : Há raiz unitária (a série é não estacionária)

Este teste é considerado mais robusto do que o teste ADF, devido ao *poder do teste*, baseado nos erros tipo I e tipo II:

- a) Tipo I – rejeitar H_0 quando ela for verdadeira
- b) Tipo II – rejeitar H_0 quando ela for falsa

ETAPA 2: Determinar a correlação linear defasada entre a variável exógena e a variável dependente para realizar a modelagem. No caso das variáveis deformações corrigidas do concreto e temperatura ambiente, verificar a correlação defasada é importante para saber com quanto tempo de atraso a temperatura ambiente influencia nas deformações corrigidas do concreto em um determinado instante de tempo, por exemplo. Esta etapa é importante, pois, diminui a possibilidade de erros na determinação dos parâmetros do modelo ajustado.

ETAPA 3: Construir o modelo SARIMAX utilizando o software *R* pelo critério de otimização *AIC* para identificar as ordens dos parâmetros do modelo ajustado. Para a modelagem no *R* foram utilizados os pacotes: *forecast*, *tseries*, *seasonal*, *stats*, *TSA*, *astsa*, *graphifcs*, *ggplot2*, e *urca*.

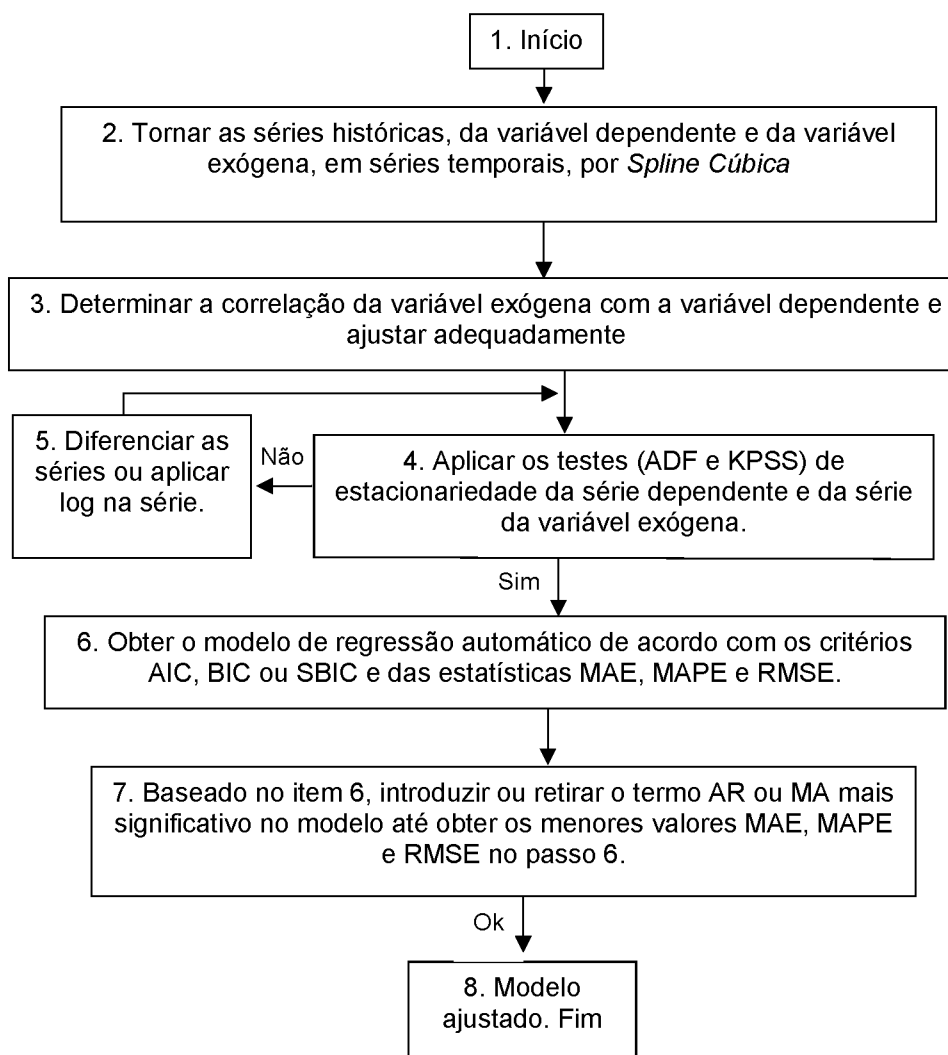
As funções FAC e FACP, dos resíduos, também auxiliam nesta etapa da modelagem por meio dos cortes nos *lags* e da visualização gráfica, auxiliando na escolha do número de parâmetros do modelo, assim como, pode-se utilizar as estatísticas *MAE*, *MAPE* e *RMSE*.

ETAPA 4: Verificar a estacionariedade dos resíduos, pelos testes ADF e KPSS. Os resíduos sendo estacionários em torno de uma média é indicativo importante de que os parâmetros do modelo ajustado foram escolhidos de forma adequada.

ETAPA 5: Na validação do modelo ajustado, é aplicado o teste de Ljung-Box para verificar se a correlação serial dos resíduos é significativa. Aplica-se o teste de Box-Pierce para verificar a nulidade das correlações individuais. O teste de Shapiro-Wilk é aplicado para verificar a normalidade dos resíduos. Estes testes implementados computacionalmente são importantes, pois, a confirmação deles indica que os resíduos são independentes, aleatórios e identicamente distribuídos (*i.i.d.*) e formam um ruído branco com distribuição $N(0, \sigma^2)$.

ETAPA 6: Obtido o modelo SARIMAX ajustado, realizar as previsões e calcular os erros de predição medidos pelas estatísticas de aderência: *MAE*, *MAPE* e *RMSE*. O cálculo destes erros é importante para identificar a acurácia do modelo ajustado e, assim, possibilitar tomada de decisões confiáveis estatisticamente. A FIGURA 15 mostra o fluxograma da modelagem SARIMAX proposta neste trabalho.

FIGURA 15 - FLUXOGRAMA DA MODELAGEM SARIMAX



FONTE: O autor (2019)

A modelagem via redes neurais *Deep Learning* com arquitetura *LSTM*, implementada nos softwares *Matlab*, foi aplicada na série dos resíduos gerados a partir da modelagem SARIMAX, para ‘capturar’ a estrutura de dependência não linear dos dados.

Na literatura é indicada, para a modelagem via redes neurais, a utilização de 70% dos dados (resíduos do modelo SARIMAX) para treinamento da rede, 20% dos dados para validação do modelo e 10% para verificação da acurácia. É importante notar que neste trabalho a porcentagem de dados utilizados para treinamento, validação e predição foi escolhida de acordo com o tamanho das séries temporais disponibilizadas pela Itaipu, sendo observada a orientação da literatura.

Cabe salientar que para o modelo SARIMAX não é necessária a separação das etapas de treinamento e validação do modelo, pois, pela metodologia Box & Jenkins, na fase de treinamento foi utilizado o critério *A/C* para identificar a ordem dos parâmetros de forma a ajustar o melhor modelo de predição. A predição final é feita recursivamente h passos à frente. A precisão do método híbrido SARIMAX-NEURAL proposto é medida pelas estatísticas de aderência ou erros *MAE*, *MAPE* e *RMSE*.

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados da aplicação do método híbrido SARIMAX-NEURAL nos testes computacionais e também gráficos dos métodos preditivos obtidos a partir da metodologia proposta. Os resultados das previsões obtidas das modelagens das séries temporais das deformações corrigidas do concreto com a temperatura ambiente, foram comparados com os métodos individuais SARIMA, RNN DL-LSTM e SARIMAX. Para os métodos SARIMA e RNN DL-LSTM as modelagens foram apenas das deformações corrigidas do concreto e para o método SARIMAX as modelagens incluíram as deformações e a temperatura ambiente.

Para verificar a acurácia das previsões foram utilizados três medidas de aderência: *MAE*, *MAPE* e *RMSE*, Hamilton (1994), definidos por:

$$MAE = \frac{1}{N} \sum_{t=1}^N |z(t) - \hat{z}(t)| \quad (35)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{z(t) - \hat{z}(t)}{z(t)} \right| \quad (36)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (z(t) - \hat{z}(t))^2} \quad (37)$$

Para cada braço de cada roseta de deformímetro foi realizada a correlação linear de Pearson, Stanton e Jeffrey (2001), entre as séries temporais da deformações corrigidas do concreto e a série temporal da temperatura ambiente, para identificar o tempo de defasagem em que as deformações corrigidas do concreto são influenciadas pela temperatura ambiente. Após identificado o tempo de defasagem, as séries são ajustadas para serem aplicadas as etapas de modelagem de acordo com a metodologia proposta para esta tese.

Em todas as cinco rosetas foram calculadas as correlações lineares defasadas para até 26 semanas de defasagem. Por exemplo, para a roseta RD-D09-5 (braço 5 da roseta) o maior índice de correlação linear foi 0,404 para 6 semanas de defasagem, isto é, a temperatura ambiente teve a maior (ainda considerada fraca) influência sobre as deformações seis semanas depois das medições de ambas no instante de tempo t . Foram calculadas as correlações

defasadas para os cinco braços de cada uma das rosetas de deformímetro RD-D09, RD-D010, RD-D011, RD-D012 e RD-D013 do bloco de contraforte D57 da usina hidrelétrica de Itaipu, que estão localizadas em diferentes posições do referido bloco (conforme FIGURA 9). A TABELA 6 apresenta os maiores índices da correlação linear de Pearson e as respectivas semanas de defasagem, em que as deformações corrigidas do concreto são influenciadas pela temperatura ambiente.

TABELA 6 – CORRELAÇÕES LINEARES DEFASADAS DAS DEFORMAÇÕES DO CONCRETO COM A TEMPERATURA AMBIENTE DE TODAS AS ROSETAS DE DEFORMÍMETRO DO BLOCO DE CONTRA FORTE D57

Braços	Coeficiente linear de Pearson (semanas defasadas)				
	RD-D09	RD-D010	RD-D011	RD-D012	RD-D013
1	0.051 (00)	0.398 (26)	-0.069 (13)	0.355 (10)	-0.158 (00)
2	0.098 (02)	0.221 (20)	-0.184 (10)	0.348 (08)	-0.158 (00)
3	0.159 (03)	0.169 (26)	-0.174 (10)	0.078 (14)	-0.163 (00)
4	0.129 (04)	0.420 (26)	-0.079 (10)	0.067 (14)	-0.157 (00)
5	0.404 (06)	0.636 (14)	0.123 (12)	0.131 (00)	-0.176 (00)

Fonte: O autor (2019)

Foram testados vários parâmetros e os utilizados no treinamento da *RNN DL- LSTM* estão apresentados na FIGURA 16.

FIGURA 16 - PRINCIPAIS PARÂMETROS UTILIZADOS NO TREINAMENTO DA REDE NEURAL RECORRENTE DEEP LEARNING COM ARQUITETURA LSTM

```

layers =
  4x1 Layer array with layers:

    1  **  Sequence Input      Sequence input with 1 dimensions
    2  **  LSTM                LSTM with 250 hidden units
    3  **  Fully Connected     1 fully connected layer
    4  **  Regression Output    mean-squared-error

opts =
  TrainingOptionsADAM with properties:

    GradientDecayFactor: 0.9000
    SquaredGradientDecayFactor: 0.9990
    Epsilon: 1.0000e-08
    InitialLearnRate: 0.0050
    LearnRateScheduleSettings: [1x1 struct]
    L2Regularization: 0
    GradientThresholdMethod: 'l2norm'
    GradientThreshold: 1
    MaxEpochs: 400
    MiniBatchSize: 128
    Verbose: 1
    VerboseFrequency: 15
    ValidationData: []
    ValidationFrequency: 50
    ValidationPatience: Inf
    Shuffle: 'every-epoch'
    CheckpointPath: ''
    ExecutionEnvironment: 'auto'
    WorkerLoad: []
    OutputFcn: []
    Plots: 'training-progress'
    SequenceLength: 'longest'
    SequencePaddingValue: 0


```

FONTE: O autor (2019)

4.1 ROSETA RD-D09-D57

A roseta RD-D-09 está localizada a montante do bloco D57, próximo do reservatório (conforme FIGURA 9). Os dados foram medidos no período de junho de 1981 até janeiro de 2018 padronizados semanalmente por *Spline Cúbica*, pois, originalmente estavam em escala de tempo diferente. Foram utilizados 1828 dados de amostra para ajuste dos métodos individuais SARIMA, SARIMAX (com período sazonal $s = 52$) e RNN DL-LSTM, para a predição foi utilizado um horizonte de predição $h = 52$, ou seja, 52 passos ou semanas à frente. Na FIGURA 17 é mostrada a série temporal da temperatura ambiente correspondente a roseta de deformímetro RD-D09-D57 (descontado o período de defasagem da correlação defasada com a série das deformações corrigidas).


FIGURA 17 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D09-D57



FONTE: O autor (2019)

Na FIGURA 18 são mostradas as séries temporais das deformações corrigidas do concreto dos cinco deformímetros (braços) da roseta de deformímetro RD-D09 do bloco de contraforte D57 da usina hidrelétrica de Itaipu.

FIGURA 18 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D09



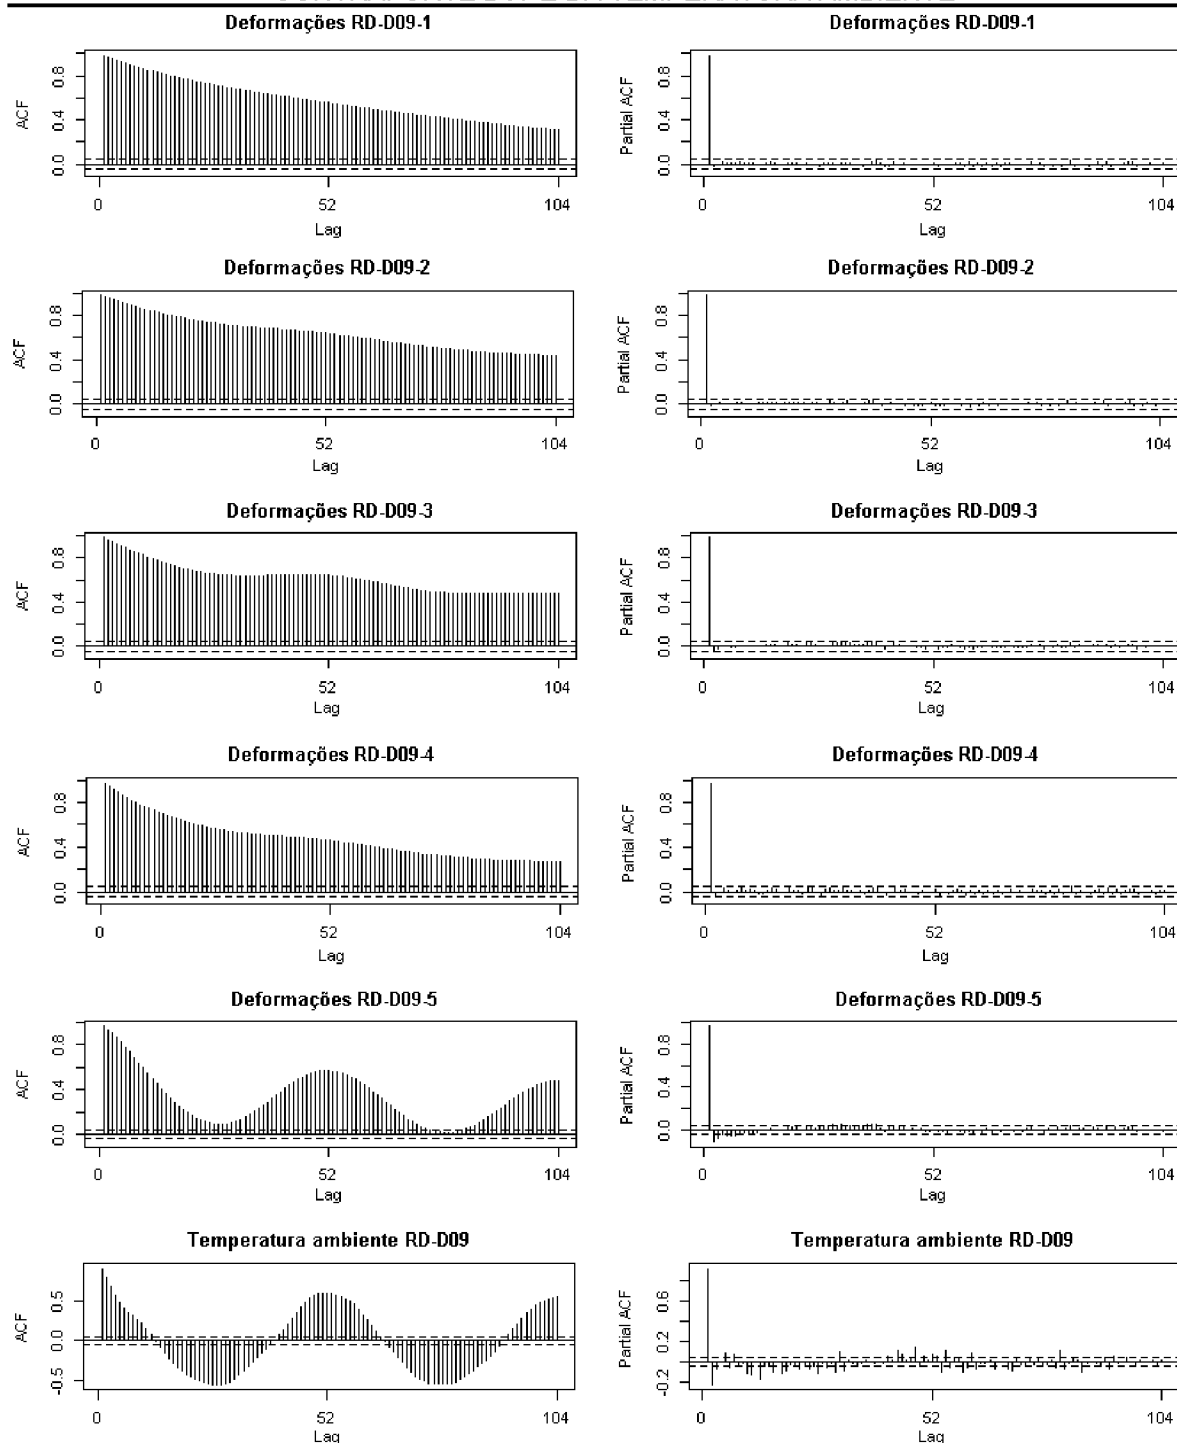
FONTE: O autor (2019)

De acordo com o fluxograma do método híbrido SARIMAX-NEURAL, proposto (ver FIGURA 14), seguem as etapas de obtenção do referido método preditivo.

Os dados históricos das deformações corrigidas do concreto e da temperatura ambiente tinham escala de tempo diferentes no período de medição dos dados históricos e foram padronizados por meio de *Spline Cúbica*, transformando os dados em séries temporais padronizadas semanalmente.

Pela análise do perfil gráfico da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP), mostrados na FIGURA 19, são considerados os *lags* até 104 semanas e se verifica que não são cumpridos os requisitos de estacionariedade (conforme a TABELA 4) para as referidas séries temporais.

FIGURA 19 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D09 DO BLOCO DE CONTRAFORTE D57 E DA TEMPERATURA AMBIENTE



FONTE: O autor (2019)

A não estacionariedade das referidas séries temporais também pode ser verificada pelo teste de raiz unitária de *ADF* e pelo teste de *KPSS* conforme a TABELA 7. Para a série temporal da temperatura ambiente, os testes de raiz unitária por

ADF resultou em -12,312 com valor-p = 0,01 indicou não estacionariedade e pelo teste *KPSS* resultou em 0,01905 com valor-p = 0,1, indicou estacionariedade. Todos os testes foram ao nível de 5%.

TABELA 7 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D09

RD-D09	ADF	valor-p	KPSS	valor-p
1	-8,5494	0,01	6,2603	0,01
2	-6,0684	0,01	8,7933	0,01
3	-6,9704	0,01	9,8616	0,01
4	-7,8189	0,01	5,8554	0,01
5	-10,886	0,01	5,6581	0,01

FONTE: o autor (2019)

No ajuste automático dos modelos preditivos, da metodologia Box & Jenkins via *software R*, foi utilizado o critério *AIC* para identificar a ordem dos modelos. Na sequência foram utilizadas o teste da Sobrefixação e as estatísticas de aderência *MAE*, *MAPE* e *RMSE* para melhorar o ajuste dos modelos preditivos aos dados das deformações corrigidas do concreto, para os cinco braços da roseta RD-D09-D57. Na TABELA 8 são mostradas as estatísticas de aderência do ajuste dos modelos SARIMA, SARIMAX e também da rede neural recorrente *DL* com arquitetura *LSTM*.

TABELA 8 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MODELOS PREDITIVOS DA ROSETA RD-D09-D57

MÉTODO	ROSETA RD-D09-1			MÉTODO	ROSETA RD-D09-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,2,3)(0,0,2)	1,08	0,25	1,69	SARIMA(4,2,5)(1,1,0)	1,29	0,22	2,04
RNN DL-LSTM	1,27	0,30	1,86	RNN DL-LSTM	1,53	0,27	2,18
SARIMAX(4,2,3)(0,1,1)	1,05	0,24	1,65	SARIMAX(0,2,1)(1,1,1)	1,33	0,22	1,93
MÉTODO	ROSETA RD-D09-3			MÉTODO	ROSETA RD-D09-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,2,4)(1,1,0)	1,22	0,24	1,96	SARIMA(5,2,4)(0,0,1)	1,04	0,29	1,63
RNN DL-LSTM	1,53	0,30	2,12	RNN DL-LSTM	1,24	0,34	1,79
SARIMAX(0,2,1)(1,1,1)	1,28	0,25	1,86	SARIMAX(4,2,3)(0,1,2)	1,05	0,28	1,62
MÉTODO	ROSETA RD-D09-5			MÉTODO	ROSETA RD-D09-6		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,2,2)(1,1,0)	1,42	0,27	2,27	SARIMA(5,2,4)(0,0,1)	1,04	0,29	1,63
RNN DL-LSTM	2,37	0,46	3,09	RNN DL-LSTM	1,24	0,34	1,79
SARIMAX(4,1,4)(1,1,1)	1,27	0,24	1,97	SARIMAX(4,2,3)(0,1,2)	1,05	0,28	1,62

FONTE: o autor (2019)

Para a análise e discussão individual foi escolhida a roseta RD-D09-5 (braço 5 desta roseta), pois, este braço está posicionado perpendicularmente ao fluxo do reservatório/rio. O modelo ajustado foi o SARIMAX(4,1,4)(1,1,1)₅₂ com período sazonal $s = 52$, por meio do software *R-Studio*. A ordem dos parâmetros do modelo automático foi escolhida pelo critério AIC e ajustada pelos critérios do MAE, MAPE e RMSE na amostra de treinamento.

As previsões foram para um horizonte de previsão $h = 52$ semanas à frente e corresponde a componente linear $\widehat{CL}_f(t)$ da previsão do método híbrido SARIMAX-NEURAL representado pela equação (33).


A componente não linear $\widehat{NL}_f(t)$ da previsão do método híbrido da equação (33) foi obtida pela modelagem via redes neurais recorrentes *RNN DL-LSTM*, por meio do software *Matlab*, aplicada aos resíduos do modelo SARIMAX(4,1,4)(1,1,1)₅₂.

O intervalo de confiança das previsões via *Bootstrap residual*, conforme descrito na seção 2.2.5, foi obtido a partir de B amostras *Bootstrap* entre [20 , 200] replicações conforme TIBSHIRANI (1996). Neste trabalho foram utilizadas $B = 40$ replicações para cada série temporal e aplicado o método híbrido SARIMAX-NEURAL para obter as novas previsões que formaram o intervalo de previsão. As replicações foram obtidas do ajuste de treinamento do método híbrido com os respectivos resíduos de cada série temporal.

A FIGURA 20 mostra os gráficos das previsões, com horizonte de previsão $h = 52$ semanas à frente e período sazonal $s = 52$, pelo método híbrido proposto com os dados de teste das deformações corrigidas do concreto para comparação da precisão de previsão e o intervalo de confiança das previsões.

Os gráficos dos intervalos de previsões das demais séries temporais desta roseta RD-D09 estão no apêndice I A desta tese.

FIGURA 20 – DADOS DE DEFORMAÇÕES E PREDIÇÕES DA SÉRIE TEMPORAL RD-D09-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL




FONTE: o autor (2019)

Também foi realizada a modelagem dos métodos individuais SARIMA e RNN DL-LSTM, sem o efeito da temperatura ambiente, para comparação das acurácias e análise da influência da temperatura ambiente nas deformações corrigidas do concreto pelo método híbrido SARIMAX-NEURAL.

Para ajustar o modelo SARIMA foram utilizados os mesmos critérios do modelo SARIMAX e obtido o modelo ajustado $SARIMA(2,2,2)(1,1,0)_{52}$ e as previsões também foram para um horizonte de predição $h = 52$ semanas à frente com período sazonal $s = 52$. Também foi realizada a modelagem via rede neural *Deep Learning* – *DL* com arquitetura *LSTM* e as previsões para um horizonte de predição $h = 52$ semanas à frente. A FIGURA 21 apresenta um comparativo das previsões do método híbrido SARIMAX-NEURAL com as previsões dos métodos individuais SARIMAX, SARIMA e RNN DL-LSTM.

FIGURA 21 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D09-5-D57



FONTE: o autor (2019)

Um dos objetivos deste trabalho é analisar a influência da temperatura ambiente nas deformações corrigidas do concreto. Por isso, nos métodos individuais foi desconsiderado o efeito da temperatura ambiente na modelagem. A TABELA 9 apresenta a comparação das acurácias do método híbrido em relação aos métodos individuais. Nota-se que as estatísticas de aderência MAE, MAPE e RMSE, das previsões pelo método híbrido proposto foram menores do que as mesmas estatísticas de previsões dos métodos individuais.

TABELA 9 - COMPARAÇÃO DAS ESTATÍSTICAS DE ADERÊNCIA DAS PREDIÇÕES DA ROSETA RD-D09-5

MÉTODO	ROSETA RD-D09-5		
	MAE	MAPE	RMSE
SARIMA(2,2,1)(1,1,0)	7,7821	1,3935	9,6823
RNN DL-LSTM	8,5760	1,5329	9,7052
SARIMAX(4,1,4)(1,1,1)	6,4372	1,1390	7,0435
SARIMAX-NEURAL	5,4715	0,9635	6,2863

FONTE: O autor (2019)

A TABELA 10 mostra a comparação dos ganhos preditivos em porcentagem do método híbrido em relação aos métodos individuais. Tais resultados demonstram a eficiência preditiva do método híbrido proposto em relação aos métodos

individuais. Isto indica que ao considerar a influência da temperatura ambiente sobre as deformações corrigidas do concreto, as predições pelo método híbrido confirmam que de fato a temperatura ambiente influencia nas deformações corrigidas do concreto, visto que, as predições pelo método híbrido tiveram melhor precisão.

TABELA 10 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D09-5

MÉTODOS INDIVIDUAIS	MÉTODO SARIMAX-NEURAL		
	MAE	MAPE	RMSE
SARIMA	29,69%	30,86%	35,07%
RNN DL-LSTM	36,20%	37,15%	35,23%
SARIMAX	15,00%	15,41%	10,75%

FONTE: O autor (2019)

Este procedimento para obtenção dos modelos preditivos, as respectivas predições e as acurácias das predições das séries temporais das deformações corrigidas do concreto, da roseta RD-D09-5, foi repetido para os demais braços da respectiva roseta. Na TABELA 11 são apresentadas as estatísticas de aderência MAE, MAPE e RMSE para comparação das acurácias do método híbrido com os respectivos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM para os braços 1, 2, 3 e 4 da roseta RD-D09.

TABELA 11 - COMAPARAÇÃO DA PRECISÃO DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA A ROSETA RD-D09


MÉTODO	ROSETA RD-D09-1			MÉTODO	ROSETA RD-D09-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,2,3)(0,0,2)	8,34	1,74	9,10	SARIMA(4,2,5)(1,1,0)	16,82	2,59	18,83
RNN DL-LSTM	8,66	1,81	9,39	RNN DL-LSTM	5,70	0,87	7,26
SARIMAX(4,2,3)(0,1,1)	7,31	1,52	7,98	SARIMAX(0,2,1)(1,1,1)	8,52	1,31	9,80
SARIMAX-NEURAL	4,51	0,94	5,16	SARIMAX-NEURAL	6,92	1,06	7,86
MÉTODO	ROSETA RD-D09-3			MÉTODO	ROSETA RD-D09-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,2,4)(1,1,0)	17,26	3,06	19,34	SARIMA(5,2,4)(0,0,1)	13,06	3,32	14,85
RNN DL-LSTM	9,95	1,39	9,38	RNN DL-LSTM	4,03	1,03	4,64
SARIMAX(0,2,1)(1,1,1)	8,39	1,49	9,79	SARIMAX(4,2,3)(0,1,2)	3,75	0,95	4,51
SARIMAX-NEURAL	5,35	0,94	6,12	SARIMAX-NEURAL	3,28	0,83	4,03

FONTE: O autor (2019)

Na FIGURA 22 são apresentadas partes das séries das deformações corrigidas do concreto e as respectivas predições pelo método híbrido SARIMAX-

NEURAL e pelos métodos individuais SARIMAX, SARIMA e RNN DL-LSTM para os braços 1, 2, 3 e 4 da roseta RD-D09.

FIGURA 22 – DADOS E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D09 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL




FONTE: O autor (2019)

Pela decomposição da série temporal é possível analisar o comportamento da série temporal correspondente a partir das previsões da referida série. Ribeiro et al. (2018) apresentaram um trabalho, em que analisaram a evolução do comportamento da série de deformação corrigida do concreto, a partir da projeção futura da curva de tendência da série temporal da roseta RD-D09-2. Foi utilizado o método SARIMA para obter as previsões e foi confirmado que o comportamento da curva de tendência seguiu a tendência da referida série temporal.

A projeção futura da tendência da série temporal da roseta RD-D09-5 foi realizada da seguinte forma: Foi feita a decomposição da série das deformações corrigidas e identificada a sua tendência, depois foi acrescentada à série original as

respectivas previsões e na série aumentada foi realizada uma nova decomposição para identificar a respectiva projeção da tendência da série original.

Na análise do comportamento da projeção futura da tendência, a partir das previsões feitas pelo método híbrido SARIMAX-NEURAL, é possível notar que a projeção futura da tendência seguiu a tendência da série original. Assim, pode-se inferir que o comportamento das deformações corrigidas do concreto nesta roseta está estável. A FIGURA 23 apresenta os respectivos gráficos da série original da roseta RD-D09-5, a curva de tendência, as previsões pelo método híbrido e a projeção futura da tendência de acordo com as respectivas previsões.




FONTE: O autor (2019)

4.2 ROSETA RD-D010-D57

A roseta RD-D010 está localizada a montante do bloco D57, próximo do lago (conforme FIGURA 9). Os dados foram medidos no período de tempo de fevereiro de 1981 até janeiro de 2017. Foram utilizados 1846 dados de amostra de treinamento para o ajuste dos métodos individuais SARIMA, SARIMAX (com período sazonal $s = 52$) e RNN DL-LSTM, para a predição foi utilizado um horizonte de predição $h = 52$, ou seja, 52 passos ou semanas à frente. Na FIGURA 24 é mostrada a série temporal da temperatura ambiente correspondente à roseta RD-D010-D57.


FIGURA 24 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D010-D57



FONTE: O autor (2019)

Na FIGURA 25 são mostradas as séries temporais das deformações corrigidas do concreto dos cinco braços da roseta de deformímetro RD-D010 do bloco de contraforte D57 da usina hidrelétrica de Itaipu.

FIGURA 25 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D010-D57



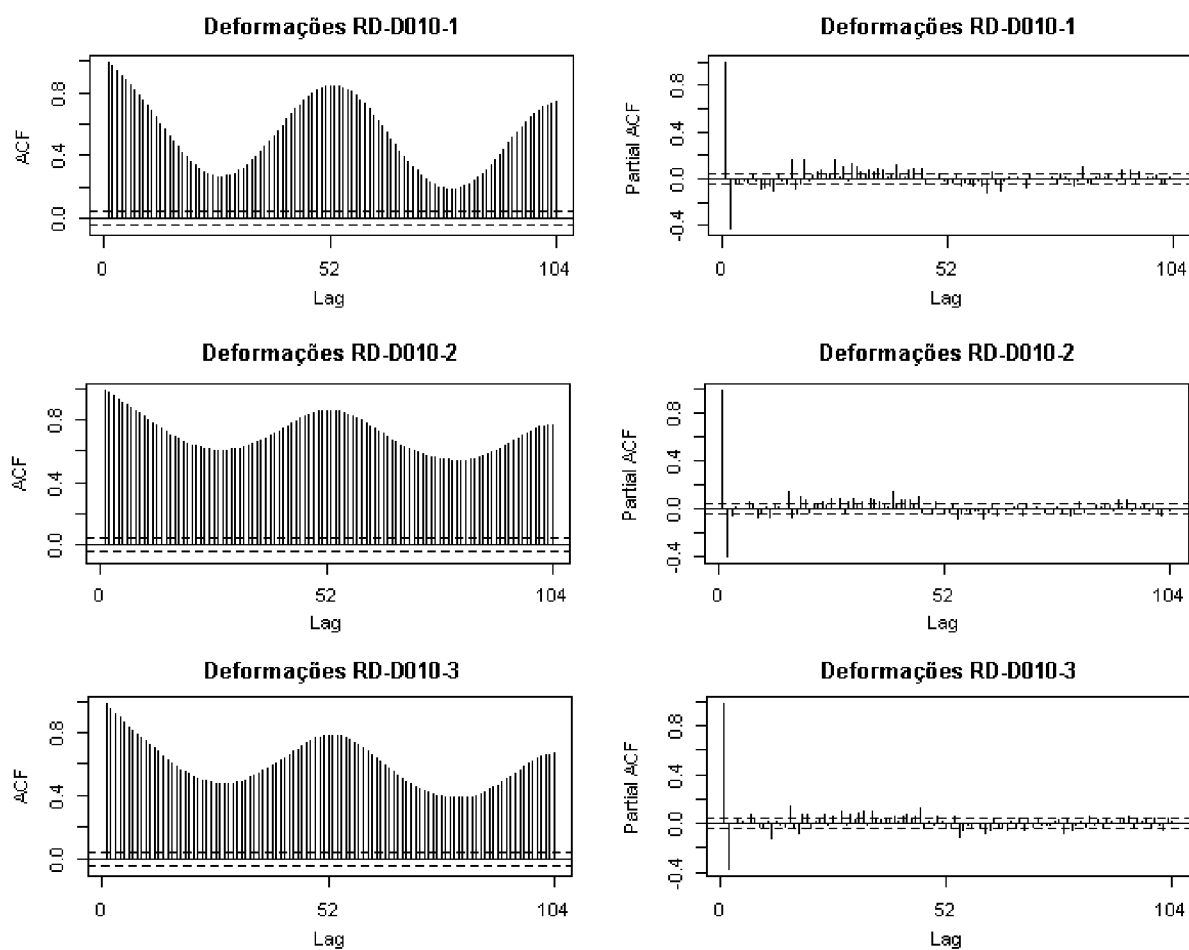
FONTE: O autor (2019)

De acordo com o fluxograma do método híbrido SARIMAX-NEURAL, proposto (ver FIGURA 14), seguem as etapas de obtenção do referido método preditivo.

Os dados históricos das deformações corrigidas do concreto e da temperatura ambiente tinham escala de tempo diferentes no período de medição dos dados históricos e foram padronizados por meio de *Spline Cúbica*, transformando os dados em séries temporais padronizadas semanalmente com período sazonal $s = 52$.

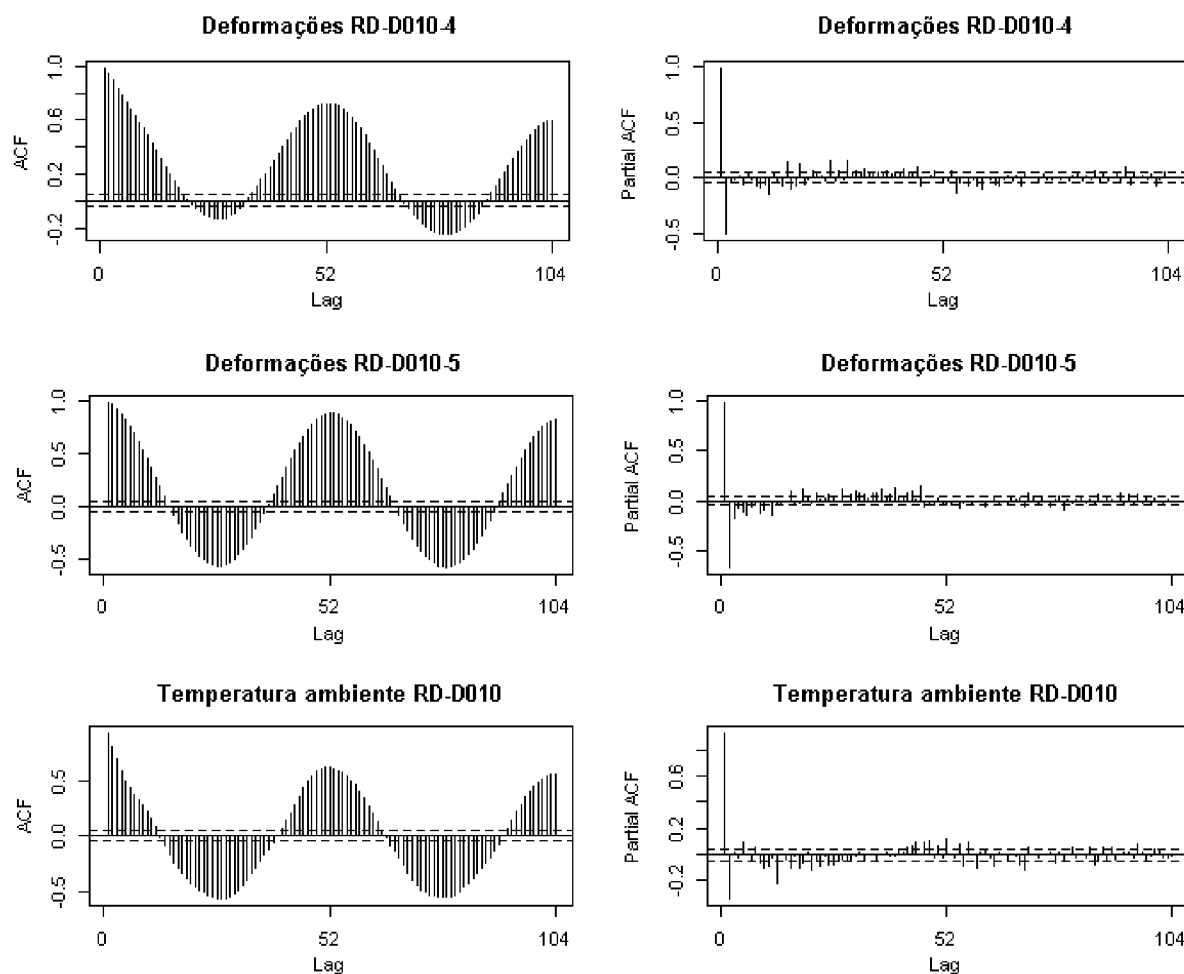
Pela análise do perfil gráfico da FAC e da FACP, conforme os critérios da TABELA 4, são mostrados nas FIGURA 26 e FIGURA 27 considerados os *lags* até 104 semanas e se verifica que não são cumpridos os requisitos de estacionariedade para as referidas séries temporais.

FIGURA 26 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D010



FONTE: O autor (2019)

FIGURA 27 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D010 E DA TEMPERATURA AMBIENTE



FONTE: O autor (2019)

Para a série temporal da temperatura ambiente, os testes de raiz unitária *ADF* resultou em -13,079 com valor-p = 0,01 indicou não estacionariedade e o *KPSS* resultou em 0,018894 com valor-p = 0,1 indicou estacionariedade. Todos os testes foram ao nível de 5%.

TABELA 12 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D010

RD-D010	ADF	valor-p	KPSS	valor-p
1	-8,4532	0,01	6,7794	0,01
2	-7,1038	0,01	11,322	0,01
3	-8,0341	0,01	10,761	0,01
4	-9,5744	0,01	2,7169	0,01
5	-15,177	0,01	1,4783	0,01

FONTE: O autor (2019)

A TABELA 13 apresenta as estatísticas de aderência utilizadas no ajuste dos modelos preditivos, da metodologia Box & Jenkins e RNN DL-LSTM, para os cinco braços da roseta RD-D010-D57. É importante observar que no ajuste dos modelos preditivos, para o método SARIMAX foi obtida melhor precisão em relação nas medidas *MAE*, *MAPE* e *RMSE* do que no ajuste dos métodos SARIMA e RNN DL-LSTM.

TABELA 13 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D010-D57

MÉTODO	ROSETA RD-D010-1			MÉTODO	ROSETA RD-D010-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,1,3)(1,1,0)	0,94	1,22	1,47	SARIMA(1,1,0)(1,1,0)	0,98	0,79	1,52
RNN DL-LSTM	1,14	1,50	1,53	RNN DL-LSTM	1,10	0,87	1,51
SARIMAX(1,1,0)(2,1,1)	0,88	1,15	1,42	SARIMAX(2,1,1)(1,1,1)	0,84	0,67	1,30
MÉTODO	ROSETA RD-D010-3			MÉTODO	ROSETA RD-D010-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(3,0,3)(1,1,0)	0,89	0,55	1,38	SARIMA(3,0,3)(1,1,0)	0,89	0,78	1,39
RNN DL-LSTM	1,04	0,64	1,41	RNN DL-LSTM	1,15	1,02	1,50
SARIMAX(4,1,3)(1,1,1)	0,79	0,49	1,22	SARIMAX(3,1,3)(1,0,1)	0,80	0,70	1,22
MÉTODO	ROSETA RD-D010-5						
	MAE	MAPE	RMSE				
SARIMA(2,0,3)(1,1,0)	0,98	0,82	1,58				
RNN DL-LSTM	1,73	1,44	3,64				
SARIMAX(2,1,1)(1,1,1)	0,89	0,75	1,42				

FONTE: O autor (2019)

Para a análise e discussão individual foi escolhida a roseta RD-D010-5 (braço 5 desta roseta), pois, está posicionada perpendicularmente ao fluxo do reservatório/rio. O modelo ajustado foi o SARIMAX(2,1,1)(1,1,1)₅₂, por meio do software *R*. A ordem dos parâmetros do modelo automático foi escolhida pelo critério *AIC* e ajustada pelos critérios do *MAE*, *MAPE* e *RMSE*, a partir do teste da Sobrefixação, na amostra de treinamento.

As predições foram para um horizonte de predição $h = 52$ semanas à frente e corresponde a componente linear $\widehat{CL}_f(t)$ da predição do método híbrido SARIMAX-NEURAL representado pela equação (33).

A componente não linear $\widehat{NL}_f(t)$ da predição do método híbrido da equação (33) foi obtida pela modelagem via redes neurais recorrentes *RNN DL*, por meio do software *Matlab*, com arquitetura *LSTM*, aplicada aos resíduos do modelo


SARIMAX(2,1,1)(1,1,1)₅₂, cujos principais parâmetros utilizados no treinamento da rede são os mesmos mostrados na FIGURA 16.

O intervalo de confiança das previsões via *Bootstrap* residual foi obtido a partir de $B = 40$ replicações *Bootstrap* para cada série temporal e aplicado o método híbrido SARIMAX-NEURAL para obter as novas previsões que formaram o intervalo de predição. As replicações foram obtidas do ajuste de treinamento do método híbrido com os respectivos resíduos de cada série temporal.

A FIGURA 28 mostra os gráficos das previsões com horizonte de previsão $h = 52$ semanas à frente e período sazonal $s = 52$, pelo método híbrido proposto, com os dados das deformações corrigidas do concreto para comparação da acurácia.

Os gráficos dos intervalos de previsões das demais séries temporais desta roseta RD-D09 estão nos anexos desta tese.

FIGURA 28 – DADOS DE DEFORMAÇÕES, INTERVALO DE PREDIÇÃO E AS PREDIÇÕES DA SÉRIE TEMPORAL RD-D010-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL




FONTE: o autor (2019)

Também foi realizada a modelagem dos métodos individuais SARIMA e RNN DL-LSTM, sem o efeito da temperatura ambiente, para comparação das acurácias e análise da influência da temperatura ambiente nas deformações corrigidas do concreto pelo método híbrido SARIMAX-NEURAL.

Para ajustar o modelo SARIMA foram utilizados os mesmos critérios do modelo SARIMAX e obtido o modelo ajustado $SARIMA(2,0,3)(1,1,0)_{52}$ e as previsões também foram para um horizonte de predição $h = 52$ semanas à frente com período sazonal $s = 52$. Também foi realizada a modelagem via *RNN DL* com arquitetura *LSTM* e previsões para um horizonte de predição $h = 52$ semanas à frente. A FIGURA 29 apresenta uma parte da série temporal das deformações corrigidas do concreto e as previsões do método híbrido SARIMAX-NEURAL com as previsões dos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM.

FIGURA 29 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D010-5-D57



FONTE: o autor (2019)

Um dos objetivos deste trabalho é analisar a influência da temperatura ambiente nas deformações corrigidas do concreto. Por isso, nos métodos individuais foi desconsiderado o efeito da temperatura ambiente na modelagem. A TABELA 14 apresenta a comparação das acurácias do método híbrido em relação aos métodos individuais.

TABELA 14 - COMPARAÇÃO DE ACURÁCIAS DAS PREDIÇÕES DO BRAÇO CINCO DA ROSETA RD-D010

MÉTODO	ROSETA RD-D010-5		
	MAE	MAPE	RMSE
SARIMA(2,0,3)(1,1,0)	4,12	3,09	4,94
RNN DL-LSTM	4,79	3,57	5,60
SARIMAX(2,1,1)(1,1,1)	4,21	3,17	5,11
SARIMAX-NEURAL	3,91	2,94	4,94

FONTE: O autor (2019)

Da TABELA 14, se observa que as estatísticas de aderência MAE, MAPE e RMSE, das predições pelo método híbrido proposto foram menores do que as mesmas estatísticas de predições dos métodos individuais. A TABELA 15 mostra a comparação dos ganhos preditivos em porcentagem do método híbrido em relação aos métodos individuais, que confirma a eficiência preditiva do método híbrido proposto em relação aos métodos individuais. Ao considerar a influência da temperatura ambiente sobre as deformações corrigidas do concreto, as predições pelo método híbrido tiveram melhor precisão com ganho de até 18%, confirmando que de fato a temperatura ambiente influencia nas deformações corrigidas do concreto.

TABELA 15 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D010-5

MÉTODOS INDIVIDUAIS	MÉTODO SARIMAX-NEURAL		
	MAE	MAPE	RMSE
SARIMA	5,31%	4,99%	0,00%
RNN DL-LSTM	18,51%	17,64%	11,63%
SARIMAX	7,15%	7,33%	3,15%

FONTE: O autor (2019)

Este procedimento para obtenção dos modelos preditivos, as respectivas predições e as acurácias, das séries temporais das deformações corrigidas do concreto, da roseta RD-D010-5, foi repetido para os demais braços da respectiva roseta. Na TABELA 16 são apresentadas as medidas de aderência MAE, MAPE e RMSE para comparação das acurácias do método híbrido com os respectivos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM para os braços 1, 2, 3 e 4 da roseta RD-D010.


TABELA 16 - COMPARAÇÃO DAS MÉDIAS DOS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA 4 BRAÇOS DA ROSETA RD-D010

MÉTODO	ROSETA RD-D010-1			MÉTODO	ROSETA RD-D010-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,1,3)(1,1,0)	4,99	5,16	6,25	SARIMA(1,1,0)(1,1,0)	4,29	2,83	5,82
RNN DL-LSTM	4,27	4,37	4,70	RNN DL-LSTM	3,20	2,05	4,64
SARIMAX(1,1,0)(2,1,1)	3,69	3,81	4,83	SARIMAX(2,1,1)(1,1,1)	2,69	1,77	3,69
SARIMAX-NEURAL	3,71	3,83	4,84	SARIMAX-NEURAL	2,70	1,78	3,70
MÉTODO	ROSETA RD-D010-3			MÉTODO	ROSETA RD-D010-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(3,0,3)(1,1,0)	4,25	2,37	4,99	SARIMA(3,0,3)(1,1,0)	3,98	3,20	4,73
RNN DL-LSTM	5,93	3,24	7,71	RNN DL-LSTM	2,34	1,88	2,81
SARIMAX(4,1,3)(1,1,1)	4,10	2,31	5,12	SARIMAX(3,1,3)(1,0,1)	4,40	3,60	5,48
SARIMAX-NEURAL	3,98	2,24	4,98	SARIMAX-NEURAL	4,37	3,58	5,47

FONTE: O autor (2019)

Na FIGURA 30 são apresentadas partes das séries das deformações corrigidas do concreto e as previsões do método híbrido SARIMAX-NEURAL e dos métodos individuais SARIMAX, SARIMA e RNN DL-LSTM para os braços 1, 2, 3 e 4 da roseta RD-D010.

FIGURA 30 – DADOS E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D010 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL




FONTE: O autor (2019)

Na análise do comportamento das deformações corrigidas do concreto, pela projeção futura da curva de tendência da série temporal, da roseta RD-D010-5 a partir das predições feitas pelo método híbrido SARIMAX-NEURAL, se observa que a projeção futura da tendência da série em questão seguiu a tendência da série original, indicando comportamento estável das respectivas deformações. A FIGURA 31 apresenta os respectivos gráficos da série original da roseta RD-D010-5, a curva de tendência, as predições pelo método híbrido e a projeção futura da tendência de acordo com as respectivas predições. Neste caso, a tendência da série pesquisada não apresentou um comportamento assintótico, que caracteriza o comportamento padrão das deformações corrigidas do concreto.

É importante destacar que esta roseta está posicionada próxima da fundação da barragem e possivelmente tenha outros fatores, não estudados aqui, que tenham interferência no comportamento da série.

FIGURA 31 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D010-5




FONTE: O autor (2019)

4.3 ROSETA RD-D011-D57

A roseta RD-D011 está localizada na base e a montante do bloco D57, próximo do lago e da função (conforme FIGURA 9). Os dados foram medidos no período de tempo de junho de 1979 até janeiro de 2018 e padronizados semanalmente por Spline Cúbica, pois, originalmente estavam em escala de tempo diferentes. Foram utilizados 1936 dados de amostra para ajuste dos métodos individuais SARIMA, SARIMAX (com período sazonal $s = 52$) e RNN DL-LSTM, para as predições foi utilizado um horizonte de predição $h = 52$, ou seja, 52 passos ou semanas à frente. Na FIGURA 32 é mostrada a série temporal da temperatura ambiente da roseta de deformímetro RD-D011-D57 (descontado o período de defasagem da correlação linear defasada com a série das deformações corrigidas do concreto).


FIGURA 32 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D011-D57



FONTE: O autor (2019)

Na FIGURA 33 são mostradas as séries temporais das deformações corrigidas do concreto dos cinco braços da roseta de deformímetro RD-D011 do bloco de contraforte D57 da usina hidrelétrica de Itaipu.

FIGURA 33 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D011-D57

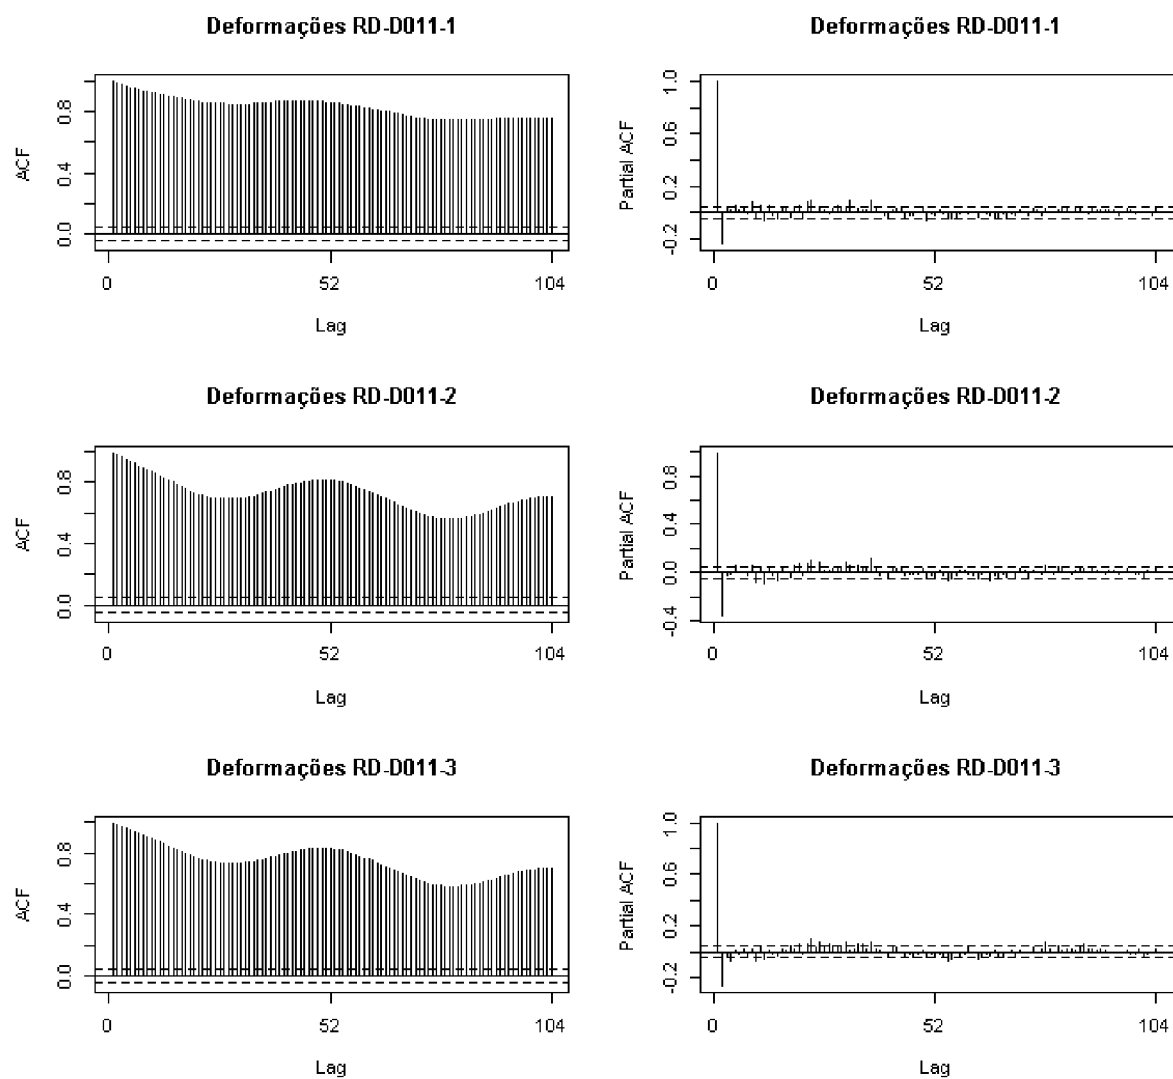


Fonte: O autor (2019)

De acordo com o fluxograma do método híbrido SARIMAX-NEURAL, proposto (ver FIGURA 14), seguem as etapas de obtenção do referido método híbrido preditivo.

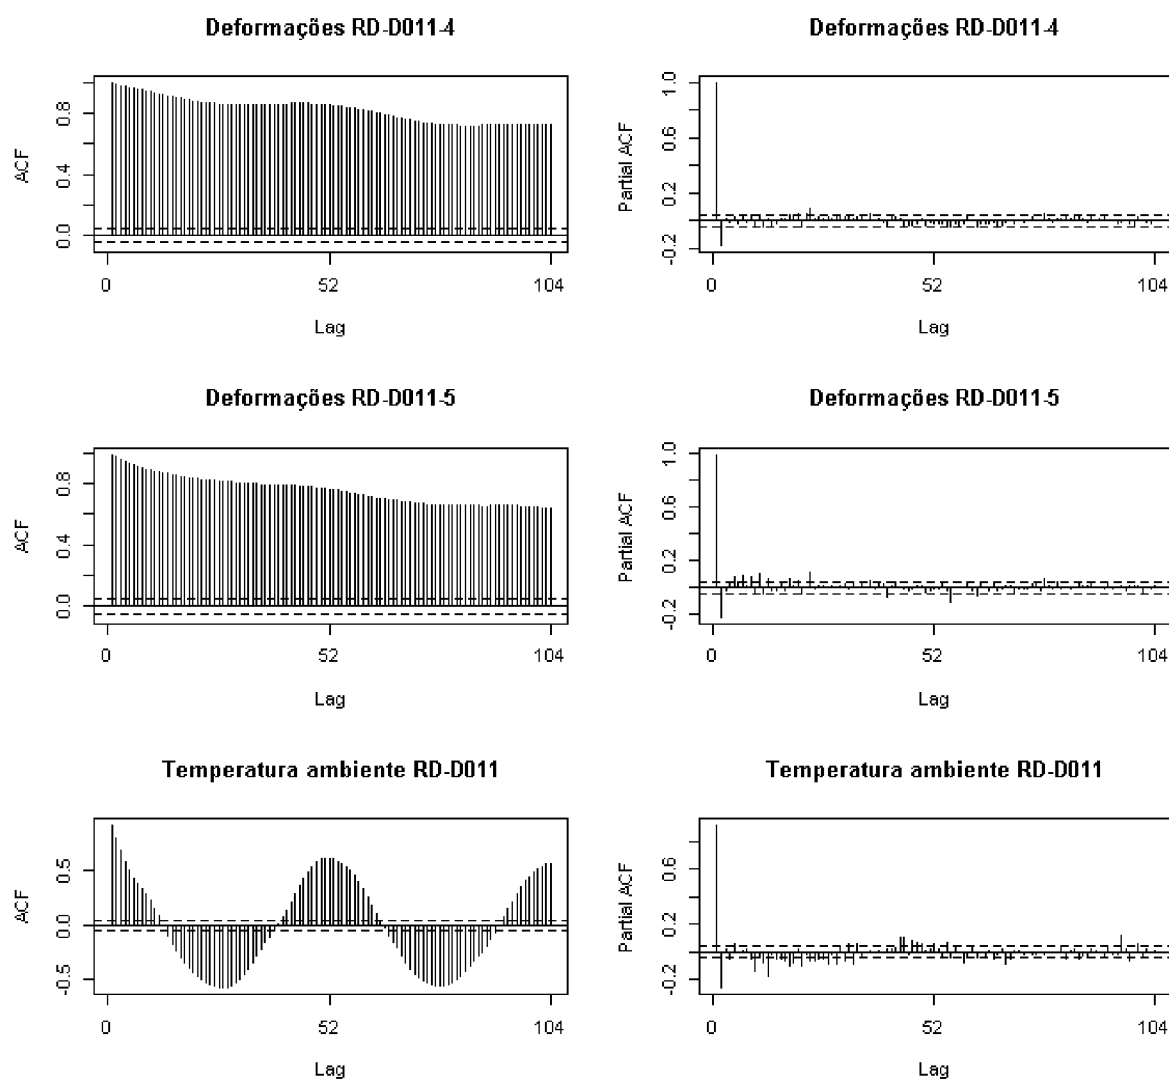
Pela análise do perfil gráfico da FAC e FACP, conforme os critérios da TABELA 4, são mostrados nas FIGURA 34 e FIGURA 35, considerados os *lags* até 104 semanas, se verifica que não são cumpridos os requisitos de estacionariedade para as referidas séries temporais.

FIGURA 34 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D011



FONTE: O autor (2019)

FIGURA 35 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D011 E DA TEMPERATURA AMBIENTE



FONTE: O autor (2019)

A não estacionariedade das referidas séries temporais também pode ser verificada pelo teste de raiz unitária *ADF* e pelo teste *KPSS* conforme a TABELA 17. Para a série temporal da temperatura ambiente, os testes de raiz unitária *ADF* resultou em -13,13 com valor-p = 0,01 que indicou não estacionariedade e o *KPSS* resultou em 0,022963 com valor-p = 0,1 indicou estacionariedade. Todos os testes foram ao nível de 5%.

TABELA 17 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D011

RD-D011	ADF	valor-p	KPSS	valor-p
1	-6,9416	0,01	16,5380	0,01
2	-6,0467	0,01	12,9870	0,01
3	-8,3202	0,01	14,5280	0,01
4	-6,4690	0,01	15,8860	0,01
5	-6,3182	0,01	15,0450	0,01

FONTE: O autor (2019)

A TABELA 18 apresenta as estatísticas de aderência utilizadas no ajuste dos modelos preditivos, da metodologia Box & Jenkins e RNN DL-LSTM, para os cinco braços da roseta RD-D011-D57. É importante observar que no ajuste dos modelos preditivos, para o método SARIMAX, que considera o efeito da temperatura ambiente nas deformações do concreto, foi obtida melhor precisão em relação às estatísticas MAE, MAPE e RMSE do que no ajuste dos métodos SARIMA e RNN DL-LSTM em quase todos os braços, com exceção dos braços 1 e 5.

TABELA 18 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MODELOS PREDITIVOS DA ROSETA RD-D011-D57

MÉTODO	ROSETA RD-D011-1			MÉTODO	ROSETA RD-D011-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(4,1,2)(1,0,1)	0,86	0,51	1,40	SARIMA(3,1,1)(1,1,0)	0,97	0,71	1,61
RNN DL-LSTM	1,08	0,63	1,57	RNN DL-LSTM	1,12	0,80	1,56
SARIMAX(4,1,2)(1,1,1)	0,87	0,51	1,39	SARIMAX(2,1,2)(1,1,1)	0,86	0,62	1,37
MÉTODO	ROSETA RD-D011-3			MÉTODO	ROSETA RD-D011-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(4,0,3)(1,1,0)	1,05	0,87	1,67	SARIMA(3,1,2)(1,1,0)	1,05	0,69	1,71
RNN DL-LSTM	1,19	0,97	1,63	RNN DL-LSTM	1,12	0,73	1,62
SARIMAX(3,1,1)(1,0,1)	0,95	0,80	1,48	SARIMAX(3,1,4)(1,0,1)	0,93	0,62	1,48
MÉTODO	ROSETA RD-D011-5			MÉTODO	ROSETA RD-D011-6		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(1,1,2)(1,0,0)	0,95	0,93	1,52	SARIMA(1,1,2)(1,0,0)	0,95	0,93	1,52
RNN DL-LSTM	1,09	1,05	1,60	RNN DL-LSTM	1,09	1,05	1,60
SARIMAX(0,1,1)(2,1,1)	1,00	0,97	1,54	SARIMAX(0,1,1)(2,1,1)	1,00	0,97	1,54


FONTE: O autor (2019)

Para a análise e discussão individual foram escolhidas as rosetas RD-D011-1 e RD-D011-2 (braços 1 e 2 desta roseta), por escolha aleatória. O modelo ajustado para a RD-D011-1 foi o SARIMAX(4,1,2)(1,1,1)₅₂ e o modelo ajustado para a RD-D011-2 foi o SARIMAX(2,1,2)(1,1,1)₅₂, ambos utilizando o software R. A ordem dos parâmetros do modelo automático foi escolhida pelo critério

AIC e ajustada por meio do teste da Sobrefixação confirmado pelos critérios do MAE , $MAPE$ e $RMSE$ na amostra de treinamento.

O intervalo de confiança das previsões via *Bootstrap* residual foi obtido de $B = 40$ replicações *Bootstrap* para cada série temporal e aplicado o método híbrido SARIMAX-NEURAL para obter as novas previsões que formaram o intervalo de predição. Como nos casos anteriores, as replicações foram obtidas do ajuste de treinamento do método híbrido com os respectivos resíduos de cada série temporal. Neste caso, os valores das séries das deformações também estão contidos no intervalo de predição, ao nível de 99% de confiança.

A FIGURA 36 mostra os gráficos das previsões com horizonte de previsão $h = 52$ semanas à frente e período sazonal $s = 52$, pelo método híbrido proposto, com os dados das deformações corrigidas do concreto para comparação da acurácia.




FONTE: O autor (2019)

Também foi realizada a modelagem dos métodos individuais SARIMA e RNN DL-LSTM, sem o efeito da temperatura ambiente, para comparação das precisões preditivas e análise da influência da temperatura ambiente nas deformações corrigidas do concreto pelo método híbrido SARIMAX-NEURAL.

Para ajustar o modelo SARIMA foram utilizados os mesmos critérios do modelo SARIMAX e obtido, para a RD-D011-1, o modelo ajustado SARIMA(4,1,2)(1,0,1)₅₂ e para a RD-D011-2 o modelo ajustado foi o SARIMA(3,1,1)(1,1,0)₅₂, as previsões também foram para um horizonte de predição $h = 52$ semanas à frente com período sazonal $s = 52$. Também foi realizada a modelagem via rede recorrente *Deep Learning* com arquitetura *LSTM* e previsões para um horizonte de predição $h = 52$ semanas à frente. A FIGURA 37 apresenta uma parte da série temporal das deformações corrigidas do concreto e as previsões do método híbrido SARIMAX-NEURAL com as previsões dos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM.

FIGURA 37 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D011-1 E RD-D011-2



FONTE: O autor (2019)

Para os métodos individuais (SARIMA e RNN DL-LSTM) foram modeladas apenas as séries temporais das deformações corrigidas do concreto, portanto, sem a influência da temperatura ambiente nos modelos de predição.

A TABELA 19 apresenta a comparação das estatísticas de aderência, que medem a precisão das predições, do método híbrido em relação aos métodos individuais.

TABELA 19 - COMPARAÇÃO DOS ERROS DAS PREDIÇÕES DOS BRAÇOS UM E DOIS DA ROSETA RD-D011

MÉTODO	ROSETA RD-D011-1			MÉTODO	ROSETA RD-D011-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(4,1,2)(1,0,1)	2,98	1,43	3,95	SARIMA(3,1,1)(1,1,0)	5,62	3,25	6,12
RNN DL-LSTM	5,35	2,52	6,24	RNN DL-LSTM	5,21	3,00	5,88
SARIMAX(4,1,2)(1,1,1)	2,94	1,40	3,30	SARIMAX(2,1,2)(1,1,1)	2,71	1,58	3,24
SARIMAX-NEURAL	2,94	1,40	3,30	SARIMAX-NEURAL	1,88	1,09	2,38

FONTE: O autor (2019)

Da TABELA 19, se observa que na RD-D011-1 as estatísticas de aderência MAE, MAPE e RMSE, das predições pelo método híbrido proposto, foram iguais às do método SARIMAX, mas em relação ao método SARIMA a precisão preditiva foi melhor e sobre o RNN DL-LSTM o ganho preditivo foi de 44% a 47% (conforme a TABELA 20). Na RD-D011-2 o método híbrido obteve maior precisão nas predições em relação aos métodos individuais. Os ganhos percentuais foram de 26% até 66% (ver TABELA 22).

Ao considerar a influência da temperatura ambiente sobre as deformações corrigidas do concreto (representado pelo método híbrido SARIMAX-NEURAL), fica evidente tal influência, visto que o método híbrido obteve melhor precisão nas predições.

TABELA 20 - COMPARAÇÃO DOS PERCENTUAIS PREDITIVOS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS EM DOIS BRAÇOS DA ROSETA RD-D011

Método SARIMAX-NEURAL						
MÉTODO	ROSETA RD-D011-1			ROSETA RD-D011-2		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
SARIMA	1,53%	2,33%	16,58%	66,59%	66,46%	61,10%
RNN DL-LSTM	45,12%	44,48%	47,16%	63,91%	63,70%	59,53%
SARIMAX	0,00%	0,00%	0,00%	30,77%	31,17%	26,62%

FONTE: O autor (2019)

Este procedimento para obtenção dos modelos preditivos, as respectivas predições e as estatísticas de aderência, das séries temporais das deformações corrigidas do concreto, das rosetas RD-D011-1 e RD-D011-2, foi repetido para os demais braços da respectiva roseta. Na TABELA 21 são apresentadas as medidas de aderência *MAE*, *MAPE* e *RMSE* para comparação das precisões do método híbrido com os respectivos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM para os braços 3, 4 e 5 da roseta RD-D011.


TABELA 21 - COMAPARAÇÃO OS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 3, 4 E 5 DA ROSETA RD-D011

MÉTODO	ROSETA RD-D011-3			MÉTODO	ROSETA RD-D011-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(4,0,3)(1,1,0)	3,21	1,93	4,61	SARIMA(3,1,2)(1,1,0)	4,50	2,19	5,20
RNN DL-LSTM	7,21	4,21	8,93	RNN DL-LSTM	2,74	1,35	3,62
SARIMAX(3,1,1)(1,0,1)	4,13	2,42	4,99	SARIMAX(3,1,4)(1,0,1)	2,02	0,98	2,47
SARIMAX-NEURAL	2,22	1,32	2,60	SARIMAX-NEURAL	1,89	0,92	2,37
MÉTODO	ROSETA RD-D011-5						
	MAE	MAPE	RMSE				
SARIMA(1,1,2)(1,0,0)	2,33	1,76	3,10				
RNN DL-LSTM	2,38	1,79	3,13				
SARIMAX(0,1,1)(2,1,1)	3,54	2,68	4,48				
SARIMAX-NEURAL	1,87	1,42	3,02				

FONTE: O autor (2019)

Na FIGURA 38 são apresentadas partes das séries das deformações corrigidas do concreto e as predições pelo método híbrido SARIMAX-NEURAL e pelos métodos individuais SARIMAX, SARIMA e RNN DL-LSTM para os braços 3, 4 e 5 da roseta RD-D011.

FIGURA 38 – DADOS DE DEFORMAÇÕES E PREDIÇÕES DE TRÊS BRAÇOS DA ROSETA RD-D011 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL




FONTE: O autor (2019)

Na análise do comportamento da curva de tendências das deformações do concreto, pela projeção futura das curvas de tendência da série temporal, da roseta RD-D011-1 e RD-D011-2 a partir das previsões feitas pelo método híbrido SARIMAX-NEURAL, se observa que as projeções futuras da tendência destas séries também seguiram a tendência das séries originais. É importante destacar que as séries temporais RD-D011-1 e RD-D011-2 têm tendência crescente, isto significa dizer que esta tendência não é assintótica.

A FIGURA 39 apresenta os respectivos gráficos das séries temporais RD-D011-1 e RD-D011-2, as curvas de tendência, as previsões pelo método híbrido e as projeções futuras da tendência de acordo com as respectivas previsões.

FIGURA 39 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D011-1 E RD-D011-2




FONTE: O autor (2019)

4.4 ROSETA RD-D012-D57

A roseta RD-D012 está localizada na base do bloco D57, próxima da fundação (conforme FIGURA 9). Os dados foram medidos no período de tempo de junho de 1979 até dezembro de 2017 e padronizados semanalmente por *Spline Cúbica*, pois, originalmente estavam em escala de tempo diferentes. Foram utilizados 1935 dados de amostra para ajuste dos métodos individuais SARIMA, SARIMAX (com período sazonal $s = 52$) e a rede neural RNN DL-LSTM, para as previsões foi utilizado um horizonte de predição $h = 52$, ou seja, 52 passos ou semanas à frente. Na FIGURA 40 é mostrada a série temporal da temperatura ambiente da roseta de deformímetro RD-D012-D57 (descontado o período de defasagem da correlação linear defasada com a série das deformações corrigidas do concreto).


FIGURA 40 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D012-D57



FONTE: O autor (2019)

Na FIGURA 41 são mostradas as séries temporais das deformações corrigidas do concreto dos cinco braços da roseta de deformímetro RD-D012 do bloco de contraforte D57 da usina hidrelétrica de Itaipu.

FIGURA 41 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D012-D57

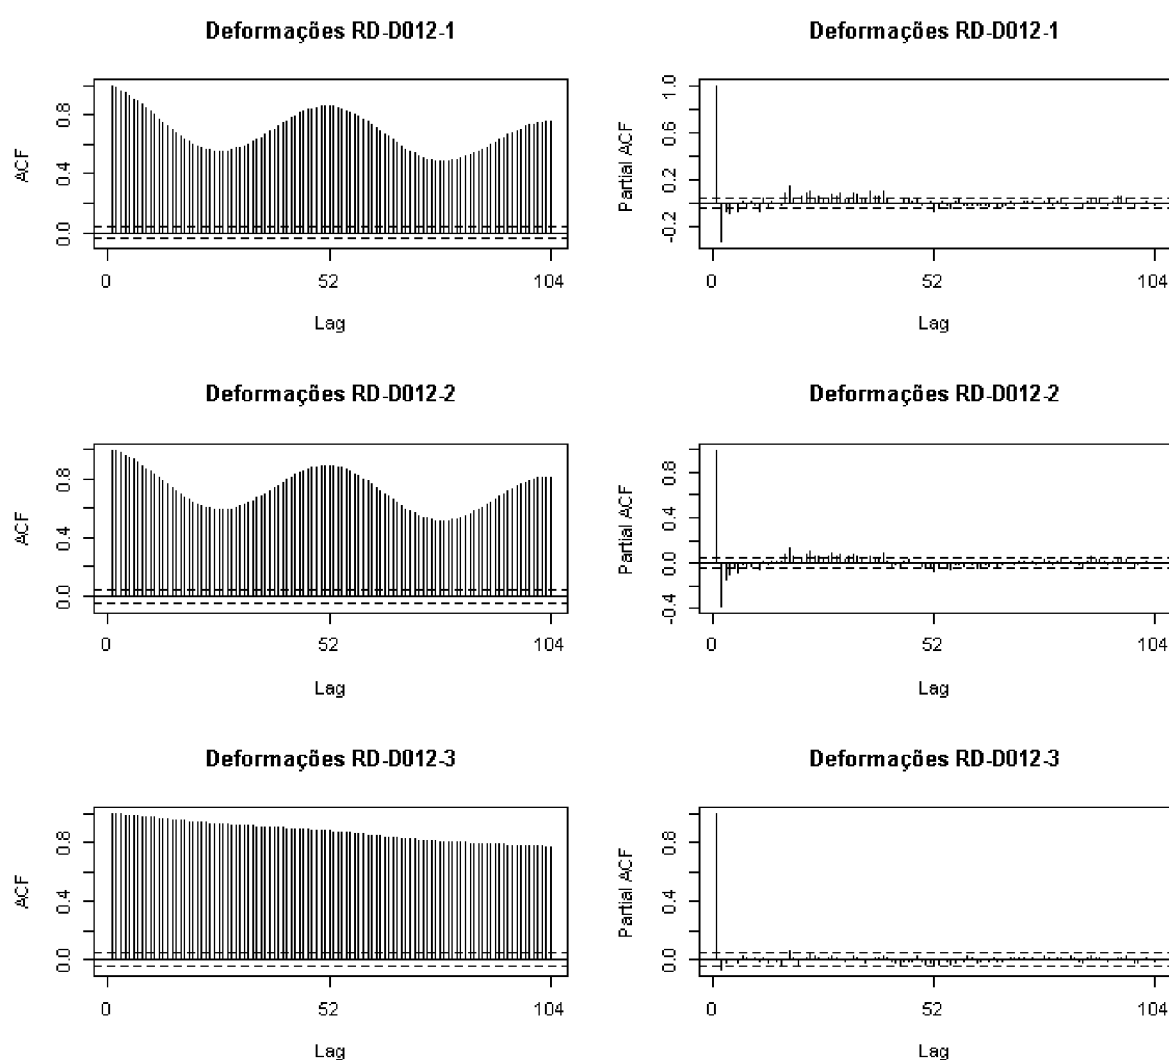


FONTE: O autor (2019)

De acordo com o fluxograma do método híbrido SARIMAX-NEURAL, proposto (ver FIGURA 14), seguem as etapas de obtenção do referido método híbrido preditivo.

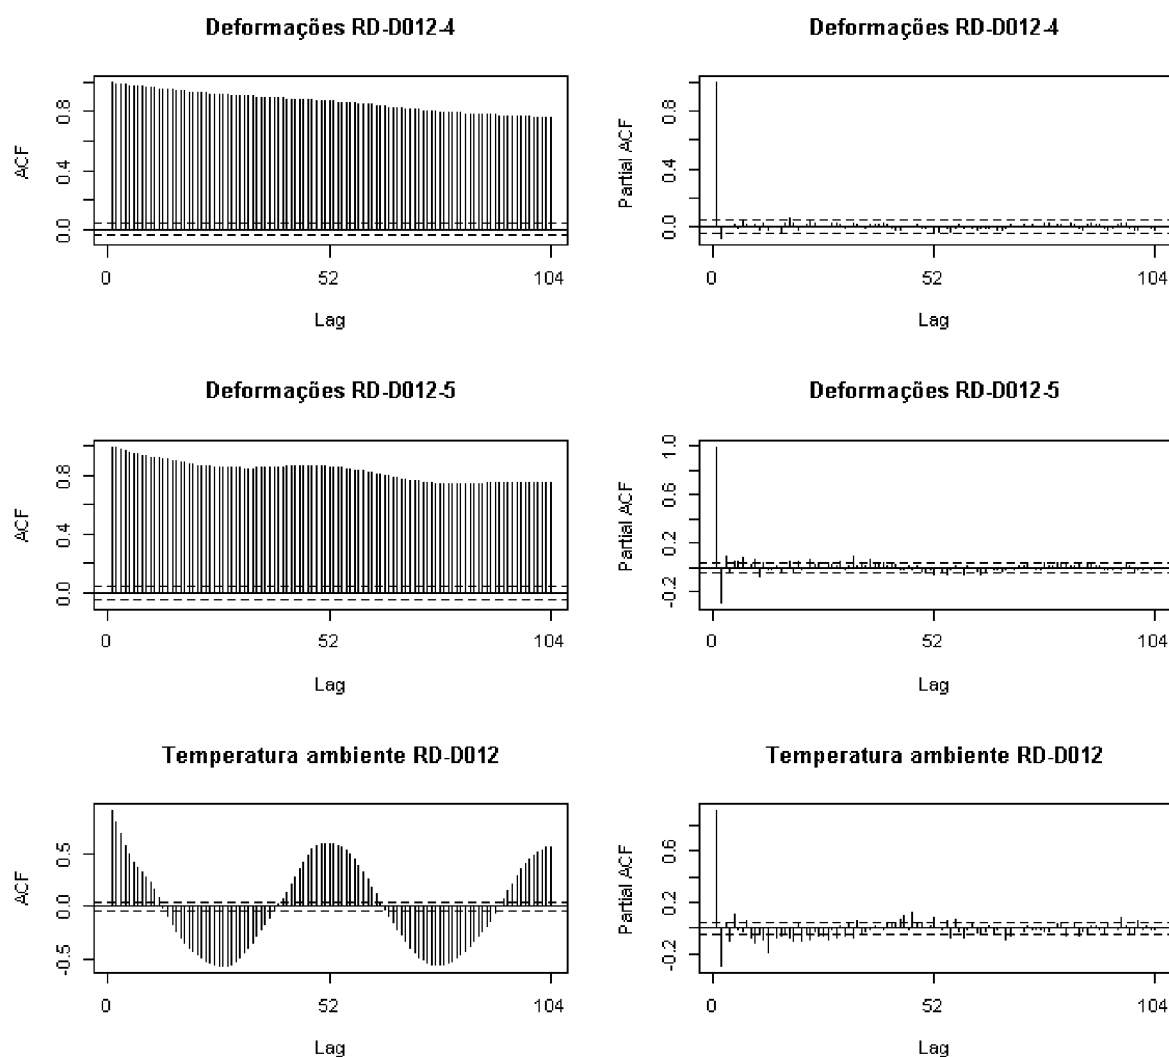
Pela análise do perfil gráfico da FAC e FACP, conforme os critérios da TABELA 4, são mostrados nas FIGURA 42 e FIGURA 43, considerados os *lags* até 104 semanas, se verifica que não são cumpridos os requisitos de estacionariedade para as referidas séries temporais.

FIGURA 42 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D012



FONTE: O autor (2019)

FIGURA 43 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D012 E DA TEMPERATURA AMBIENTE



FONTE: O autor (2019)

A não estacionariedade das referidas séries temporais também pode ser verificada pelo teste de raiz unitária *ADF* e *KPSS* conforme a TABELA 22. Para a série temporal da temperatura ambiente, os testes de raiz unitária *ADF* que resultou em

-13,243 com valor-p = 0,01 que indicou não estacionariedade e o *KPSS* resultou em 0,016 com valor-p = 0,1 indicou estacionariedade. Todos os testes foram ao nível de 5%.

TABELA 22 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D012

RD-D012	ADF	valor-p	KPSS	valor-p
1	-13,002	0,01	13,284	0,01
2	-12,676	0,01	14,192	0,01
3	-4,4232	0,01	16,945	0,01
4	-4,8143	0,01	16,519	0,01
5	-7,7517	0,01	16,460	0,01

FONTE: O autor (2019)

A TABELA 23 apresenta as estatísticas de aderência utilizadas no ajuste dos modelos preditivos, da metodologia Box & Jenkins e RNN DL-LSTM, para os cinco braços da roseta RD-D012-D57. É importante observar que no ajuste dos modelos preditivos, para o método SARIMAX foi obtida melhor precisão nas estatísticas MAE, MAPE e RMSE do que no ajuste dos métodos individuais SARIMA e RNN DL-LSTM em todos os 5 braços.

TABELA 23 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D012-D57

MÉTODO	ROSETA RD-D012-1			MÉTODO	ROSETA RD-D012-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,1,1)(1,1,0)	1,43	0,63	2,03	SARIMA(1,1,0)(1,1,0)	1,21	0,88	1,89
RNN DL-LSTM	1,62	0,71	2,18	RNN DL-LSTM	1,85	1,31	2,37
SARIMAX(1,1,0)(2,1,1)	1,22	0,54	1,89	SARIMAX(2,1,1)(1,0,0)	1,05	0,77	1,65
MÉTODO	ROSETA RD-D012-3			MÉTODO	ROSETA RD-D012-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(3,0,3)(1,1,0)	1,31	0,83	2,06	SARIMA(2,1,1)(1,1,0)	1,32	0,52	2,05
RNN DL-LSTM	1,35	0,88	1,94	RNN DL-LSTM	1,41	0,56	2,01
SARIMAX(4,1,3)(1,1,1)	1,26	0,80	1,96	SARIMAX(1,1,2)(1,1,1)	1,09	0,45	1,75
MÉTODO	ROSETA RD-D012-5			MÉTODO	ROSETA RD-D012-6		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,0,3)(1,1,0)	1,05	0,75	4,36	SARIMA(2,1,1)(1,1,1)	1,05	0,75	4,36
RNN DL-LSTM	1,24	0,89	1,73	RNN DL-LSTM	1,24	0,89	1,73
SARIMAX(2,1,1)(1,1,1)	0,98	0,71	1,50	SARIMAX(2,1,1)(1,1,1)	0,98	0,71	1,50


FONTE: o autor (2019)

Para a análise e discussão individual foram escolhidas as rosetas RD-D012-1 e RD-D012-2 (braços 1 e 2 desta roseta), por escolha aleatória. O modelo ajustado para a RD-D012-1 foi o SARIMAX(1,1,0)(2,1,1)₅₂ e o modelo ajustado para a RD-D012-2 foi o SARIMAX(2,1,1)(1,0,0)₅₂, ambos utilizando o software R. A ordem dos parâmetros do modelo automático foi escolhida pelo critério AIC e ajustada pelos critérios do MAE, MAPE e RMSE na amostra de treinamento.

O intervalo de confiança das previsões via *Bootstrap residual* foi obtido de $B = 40$ replicações *Bootstrap* para cada série temporal e aplicado o método híbrido SARIMAX-NEURAL para obter as novas previsões que formaram o intervalo de predição. As replicações foram obtidas do ajuste de treinamento do método híbrido com os respectivos resíduos de cada série temporal. Os valores das respectivas séries das deformações também estão contidos no intervalo de predição, ao nível de 99% de confiança.

A FIGURA 44 mostra os gráficos das previsões, pelo método híbrido proposto, com horizonte de previsão $h = 52$ semanas à frente e período sazonal $s = 52$ com os dados das deformações corrigidas do concreto para comparação da precisão dos erros e também o intervalo de predição no qual a melhor predição possível, isto é com erro zero deva estar.

FIGURA 44 – DADOS DE DEFORMAÇÕES, INTERVALOS DE PREDIÇÕES E AS PREDIÇÕES DAS SÉRIES TEMPORAIS RD-D012-1 E RD-D012-2 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL




FONTE: o autor (2019)

Também foi realizada a modelagem dos métodos individuais SARIMA e RNN DL-LSTM, sem o efeito da temperatura ambiente, para comparação dos erros e análise da influência da temperatura ambiente nas deformações corrigidas do concreto pelo método híbrido SARIMAX-NEURAL.

Para ajustar o modelo SARIMA foram utilizados os mesmos critérios do modelo SARIMAX e obtido, para a RD-D012-1, o modelo ajustado SARIMA(3,0,3)(1,1,0)₅₂ e para a RD-D012-2 o modelo ajustado foi o SARIMA(1,1,0)(1,1,0)₅₂. As previsões também foram para um horizonte de predição $h = 52$ semanas à frente com período sazonal $s = 52$. Também foi realizada a modelagem via rede recorrente *Deep Learning - DL* com arquitetura LSTM e previsões para um horizonte de predição $h = 52$ semanas à frente. A FIGURA 45 apresenta uma parte da série temporal das deformações corrigidas do concreto e as previsões do método híbrido SARIMAX-NEURAL com as respectivas previsões dos métodos individuais, SARIMAX, SARIMA e RNN DL-LSTM.

FIGURA 45 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D012-1 E RD-D012-2



FONTE: o autor (2019)

A TABELA 24 apresenta a comparação das estatísticas de aderência MAE, MAPE e RMSE do método híbrido em relação aos métodos individuais.

TABELA 24 - COMPARAÇÃO DAS ESTATÍSTICAS DE ADERÊNCIA DAS PREDIÇÕES DOS BRAÇOS UM E DOIS DA ROSETA RD-D012

MÉTODO	ROSETA RD-D012-1			MÉTODO	ROSETA RD-D012-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(2,1,1)(1,1,0)	3,86	1,43	5,81	SARIMA(1,1,0)(1,1,0)	5,88	2,92	7,21
RNN DL-LSTM	5,57	2,04	6,96	RNN DL-LSTM	7,40	3,67	8,25
SARIMAX(1,1,0)(2,1,1)	3,47	1,28	5,29	SARIMAX(2,1,1)(1,0,0)	5,55	2,77	6,93
SARIMAX-NEURAL	3,51	1,30	5,32	SARIMAX-NEURAL	5,49	2,74	6,87

FONTE: o autor (2019)

Da TABELA 24, se observa que as estatísticas de aderência mencionadas, das previsões pelo método híbrido proposto, não foram menores do que as mesmas estatísticas de previsões dos métodos individuais na RD-D012-1, embora, estas mesmas estatísticas foram menores no ajuste dos respectivos métodos preditivos. É de se destacar que o melhor ajuste na fase de treinamento não garante a melhor previsão fora da amostra de treinamento. No entanto, na RD-D012-2 o método híbrido teve melhor precisão nas previsões em relação aos métodos individuais.

Na RD-D012-1, a precisão preditiva foi melhor e sobre o SARIMA e RNN DL-LSTM com ganho preditivo entre 8% e 37%. Na RD-D012-2 o método híbrido obteve maior precisão nas previsões em relação aos métodos individuais, com ganhos percentuais entre 6% e 26% (conforme a TABELA 26).

Ao considerar a influência da temperatura ambiente sobre as deformações corrigidas do concreto (representado pelo método híbrido SARIMAX-NEURAL), fica evidente tal influência, visto que, o método híbrido obteve melhor precisão nas previsões.

TABELA 25 - COMPARAÇÃO DA PRECISÃO PERCENTUAL PREDITIVA DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS EM DOIS BRAÇOS DA ROSETA RD-D012

Método SARIMAX-NEURAL						
MÉTODO	ROSETA RD-D012-1			ROSETA RD-D012-2		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
SARIMA	9,14%	9,19%	8,37%	6,66%	5,91%	4,68%
RNN DL-LSTM	36,97%	36,42%	23,56%	25,84%	25,32%	16,71%
SARIMAX	-1,00%	-0,99%	-0,50%	1,09%	1,08%	0,78%

FONTE: o autor (2019)

O fato desta roseta estar na base ou na fundação do bloco da barragem pode ser uma possível causa de o método híbrido não ter melhor precisão de predição sobre o SARIMAX na RD-D012-1, pois, a incidência solar neste local é mínima, além da umidade.

Este procedimento para obtenção dos métodos preditivos, as respectivas predições e as acurácias, das séries temporais das deformações corrigidas do concreto, das rosetas RD-D012-1 e RD-D012-2, foi repetido para os demais braços da respectiva roseta. Na TABELA 26 são apresentadas as estatísticas de aderência MAE, MAPE e RMSE para comparação das acurácias do método híbrido com os respectivos métodos individuais, SARIMA, RNN DL-LSTM e SARIMAX para os braços 3, 4 e 5 da roseta RD-D012.

TABELA 26 - COMAPARAÇÃO DOS ERROS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 3, 4 E 5 DA ROSETA RD-D012


MÉTODO	ROSETA RD-D012-3			MÉTODO	ROSETA RD-D012-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(3,0,3)(1,1,0)	5,26	1,88	5,97	SARIMA(2,1,1)(1,1,0)	4,13	1,18	4,97
RNN DL-LSTM	13,19	4,73	13,81	RNN DL-LSTM	6,07	1,73	7,68
SARIMAX(4,1,3)(1,1,1)	3,76	1,35	4,46	SARIMAX(1,1,2)(1,1,1)	3,01	0,86	3,62
SARIMAX-NEURAL	3,67	1,31	4,42	SARIMAX-NEURAL	2,96	0,85	3,58

MÉTODO	ROSETA RD-D012-5		
	MAE	MAPE	RMSE
SARIMA(2,0,3)(1,1,0)	3,10	1,73	3,62
RNN DL-LSTM	3,88	2,15	4,44
SARIMAX(2,1,1)(1,1,1)	3,01	1,68	3,47
SARIMAX-NEURAL	3,04	1,70	3,50

FONTE: O autor (2019)

Na FIGURA 46 são apresentadas partes das séries das deformações corrigidas do concreto e as predições pelo método híbrido SARIMAX-NEURAL e pelos métodos individuais SARIMAX, SARIMA e RNN DL-LSTM para os braços 3, 4 e 5 da roseta RD-D012.

FIGURA 46 – DADOS E PREDIÇÕES DE TRÊS BRAÇOS DA ROSETA RD-D012 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL




FONTE: O autor (2019)

Na análise do comportamento da curva de tendência das deformações do concreto, pela projeção futura da curva de tendência da série temporal, da RD-D012-1 e RD-D012-2 a partir das previsões feitas pelo método híbrido SARIMAX-NEURAL, se observa que a projeção futura da tendência das referidas séries também seguiram a tendência das séries originais. É importante destacar que ambas as séries temporais RD-D012-1 e RD-D012-2 originais têm tendência crescente, e que houve mudança de regime no segundo semestre de 1999 e primeiro semestre de 2010 (ver FIGURA 47). Isto significa dizer que a tendência não é assintótica. Não foi obtida nenhuma informação técnica sobre esta mudança de regime, mas é possível inferir que a tendência da RD-D012 tem um comportamento crescente ao longo do tempo.

A FIGURA 47 apresenta os respectivos gráficos das séries originais RD-D012-1 e RD-D012-12, a curva de tendência, as previsões pelo método híbrido e a projeção futura da tendência de acordo com as respectivas previsões.

FIGURA 47 – PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D012-1 E RD-D012-2




FONTE: O autor (2019)

4.5 ROSETA RD-D013-D57

A roseta RD-D013 está localizada próxima da base e a jusante do bloco D57 (conforme FIGURA 9), sendo que nesta posição ocorre a maior incidência solar sobre o referido bloco de concreto. Os dados foram medidos no período de tempo de junho de 1979 até janeiro de 2018 e padronizados semanalmente por *Spline Cúbica*, pois, originalmente estavam em escala de tempo diferentes. Foram utilizados 1936 dados de amostra para ajuste dos métodos individuais SARIMA, SARIMAX (com período sazonal $s = 52$) e a rede neural RNN DL-LSTM. Para as previsões foi utilizado um horizonte de predição $h = 52$, ou seja, 52 passos ou semanas à frente. Na FIGURA 48 é mostrada a série temporal da temperatura ambiente da roseta de deformímetro RD-D013-D57 (descontado o período de

defasagem da correlação defasada com a série das deformações corrigidas do concreto).


FIGURA 48 - SÉRIE TEMPORAL DA TEMPERATURA AMBIENTE CORRESPONDENTE A ROSETA RD-D013-D57



FONTE: O autor (2019)

Na FIGURA 49 são mostradas as séries temporais das deformações corrigidas do concreto dos cinco braços da roseta de deformímetro RD-D013 do bloco de contraforte D57 da usina hidrelétrica de Itaipu.

FIGURA 49 - SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA DE DEFORMÍMETRO RD-D013-D57

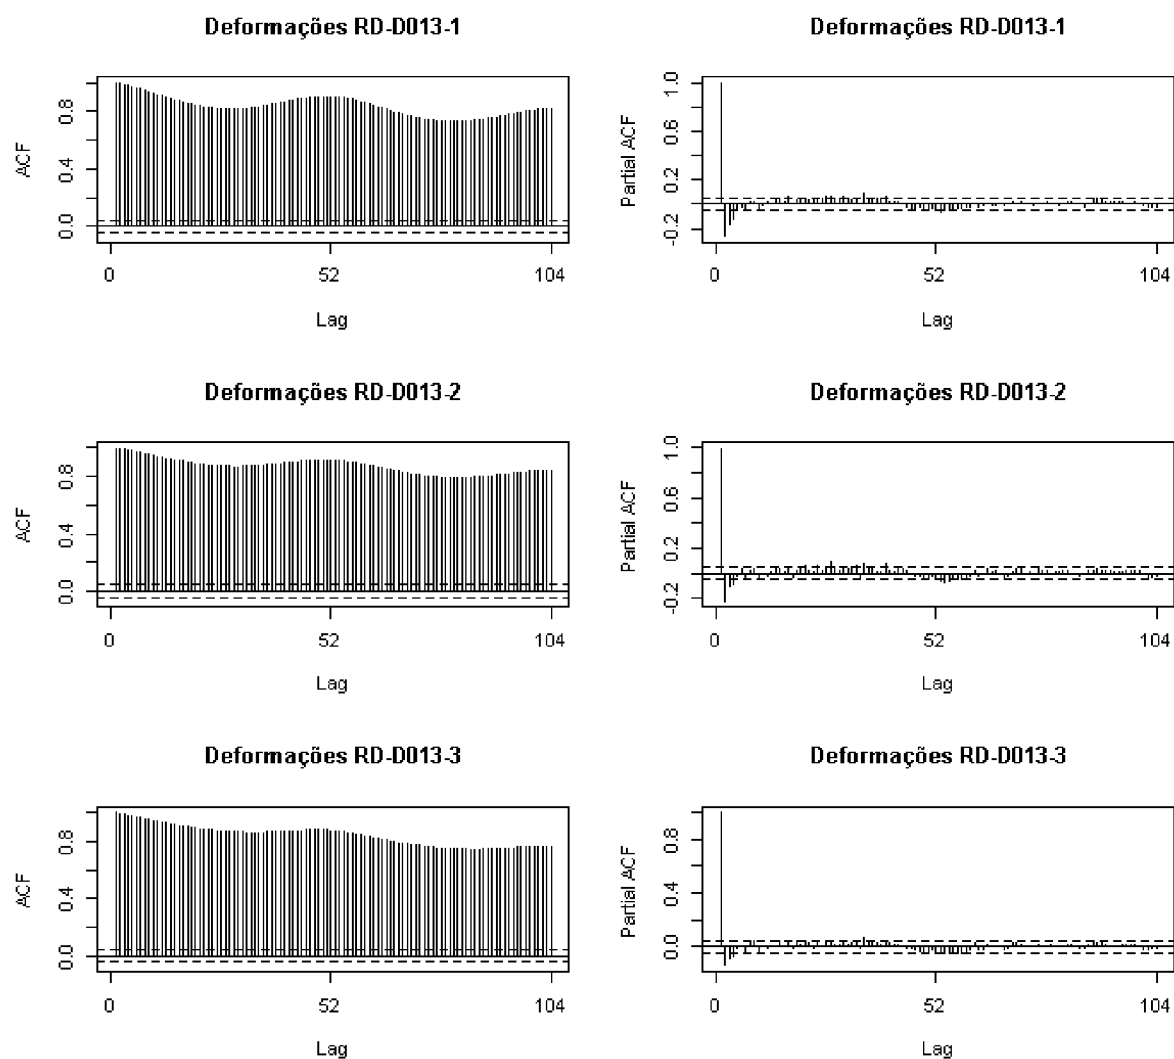


FONTE: O autor (2019)

De acordo com o fluxograma do método híbrido SARIMAX-NEURAL, proposto (ver FIGURA 14), seguem as etapas de obtenção do referido método híbrido preditivo.

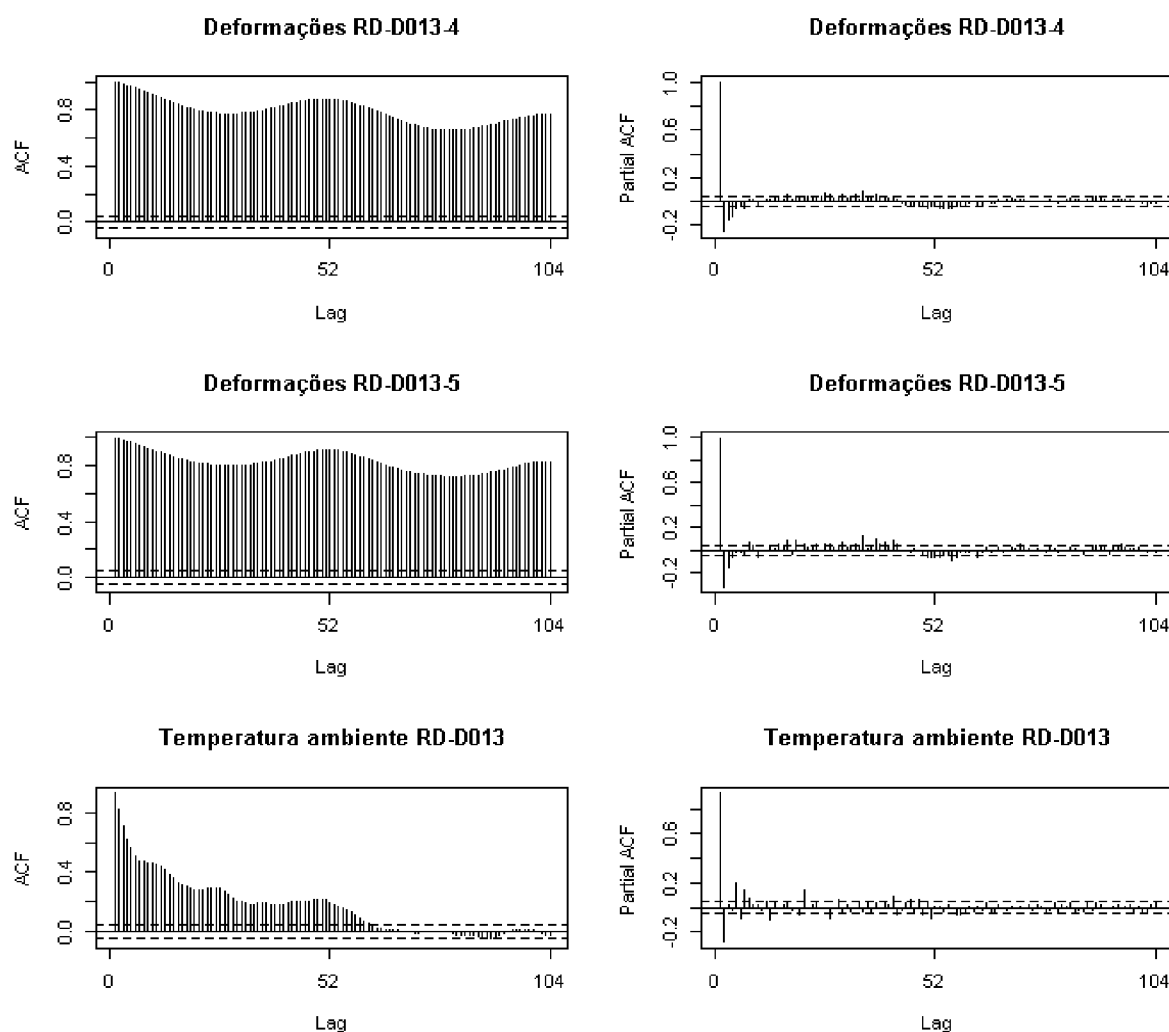
Pela análise do perfil gráfico da FAC e da FACP, conforme os critérios da TABELA 4, são mostrados nas FIGURA 50 e FIGURA 51, considerados os *lags* até 104 semanas, se verifica que não são cumpridos os requisitos de estacionariedade para as referidas séries temporais.

FIGURA 50 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 1, 2 E 3 DA ROSETA RD-D013



FONTE: O autor (2019)

FIGURA 51 - PERFIL GRÁFICO DA FAC E DA FACP DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DOS BRAÇOS 4 E 5 DA ROSETA RD-D013 E DA TEMPERATURA AMBIENTE



FONTE: O autor (2019)

Para a série temporal da temperatura ambiente, os testes de raiz unitária *ADF* resultou em -6,8916 com valor-p = 0,01 que indicou não estacionariedade e o *KPSS* resultou em 0,75009 com valor-p = 0,01 indicou não estacionariedade. Todos os testes foram ao nível de 5%.

TABELA 27 - TESTES ADF E KPSS PARA VERIFICAR A ESTACIONARIEDADE DAS SÉRIES TEMPORAIS DAS DEFORMAÇÕES DA ROSETA RD-D012

RD-D012	ADF	valor-p	KPSS	valor-p
1	-9,9416	0,01	16,4070	0,01
2	-6,6822	0,01	16,5480	0,01
3	-7,0896	0,01	16,1970	0,01
4	-9,3367	0,01	15,2290	0,01
5	-6,9670	0,01	14,8270	0,01

FONTE: O autor (2019)

A TABELA 28 apresenta as estatísticas de aderência utilizadas no ajuste dos modelos preditivos, da metodologia Box & Jenkins e RNN DL-LSTM, para os cinco braços da roseta RD-D013-D57. É importante observar que no ajuste dos modelos preditivos, para o método SARIMAX (que considera o efeito da temperatura ambiente sobre as deformações do concreto) foi obtida melhor precisão nas estatísticas MAE, MAPE e RMSE do que no ajuste dos métodos individuais SARIMA e RNN DL-LSTM em todos os 5 braços.

TABELA 28 - ESTATÍSTICAS DE ADERÊNCIA UTILIZADAS NO AJUSTE DOS MÉTODOS PREDITIVOS DA ROSETA RD-D013-D57

MÉTODO	ROSETA RD-D013-1			MÉTODO	ROSETA RD-D013-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(5,1,4)(2,1,0)	1,22	1,32	1,84	SARIMA(4,1,5)(2,1,0)	1,14	1,13	1,72
RNN DL-LSTM	2,16	2,26	2,75	RNN DL-LSTM	1,60	1,46	2,06
SARIMAX(4,1,3)(1,1,1)	1,13	1,23	1,70	SARIMAX(1,1,0)(1,1,0)	1,24	1,22	1,88
MÉTODO	ROSETA RD-D013-3			MÉTODO	ROSETA RD-D013-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(5,1,3)(2,1,1)	1,23	0,77	1,88	SARIMA(3,1,1)(1,1,0)	1,64	1,06	2,51
RNN DL-LSTM	1,78	1,07	2,34	RNN DL-LSTM	2,82	1,72	3,57
SARIMAX(4,1,2)(1,1,1)	1,23	0,78	1,86	SARIMAX(3,1,1)(1,1,1)	1,49	0,98	2,25
MÉTODO	ROSETA RD-D013-5						
	MAE	MAPE	RMSE				
SARIMA(3,0,2)(1,1,0)	1,89	3,80	2,84				
RNN DL-LSTM	2,35	4,69	3,09				
SARIMAX(3,1,2)(1,1,0)	1,86	3,86	2,84				

FONTE: o autor (2019)


Para a análise e discussão individual foi escolhida a roseta RD-D013-5 (braço 5 da roseta), por estar na posição ortogonal ao fluxo do reservatório. O modelo ajustado para a RD-D013-5 foi o SARIMAX(3,1,2)(1,1,0)₅₂, por meio do software *R*. A ordem dos parâmetros do modelo automático foi escolhida pelo critério AIC e ajustada pelos critérios do MAE, MAPE e RMSE na amostra de treinamento.

As previsões foram calculadas para um horizonte de predição $h = 52$ semanas à frente e corresponde a componente linear $\widehat{CL}_f(t)$ da predição do método híbrido SARIMAX-NEURAL representado pela equação (33).

A FIGURA 52 mostra os gráficos das previsões, pelo método híbrido proposto, com horizonte de previsão $h = 52$ semanas à frente e período sazonal $s =$

52 com os dados das deformações corrigidas do concreto para comparação da precisão preditiva e também o intervalo de confiança via *Bootstrap* residual das respectivas predições.

FIGURA 52 – DADOS DE DEFORMAÇÕES E AS PREDIÇÕES COM O INTERVALO DE CONFIANÇA DA SÉRIE TEMPORAL RD-D013-5 PELO MÉTODO HÍBRIDO SARIMAX-NEURAL




FONTE: o autor (2019)

Também foi realizada a modelagem dos métodos individuais SARIMA e RNN DL-LSTM, sem o efeito da temperatura ambiente, para comparação das acurácias e análise da influência da temperatura ambiente nas deformações corrigidas do concreto pelo método híbrido SARIMAX-NEURAL.

Para ajustar o modelo SARIMA foram utilizados os mesmos critérios do modelo SARIMAX e obtido, para a RD-D013-5, o modelo ajustado SARIMA(3,0,2)(1,1,0)₅₂. As predições também foram para um horizonte de predição $h = 52$ semanas à frente com período sazonal $s = 52$. Também foi realizada a modelagem via rede recorrente Deep Learning - DL com arquitetura LSTM e predições para um horizonte de predição $h = 52$ semanas à frente. A FIGURA 53 apresenta uma parte da série temporal das deformações corrigidas do concreto e as predições do método híbrido SARIMAX-NEURAL com as predições dos métodos individuais, SARIMAX, SARIMA e DL-LSTM.

FIGURA 53 – DADOS DE DEFORMAÇÕES E COMPARAÇÃO DE PREDIÇÕES DE DIFERENTES MÉTODOS DA ROSETA RD-D013-5



FONTE: o autor (2019)

A TABELA 29 apresenta a comparação das estatísticas de aderência *MAE*, *MAPE* e *RMSE* do método híbrido em relação aos métodos individuais.

TABELA 29 - COMPARAÇÃO DA PRECISÃO DAS PREDIÇÕES DA ROSETA RD-D013-5 EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS

MÉTODO	ROSETA RD-D013-5		
	MAE	MAPE	RMSE
SARIMA(3,0,2)(1,1,0)	3,9418	2,8264	4,7289
RNN DL-LSTM	4,7509	3,4074	5,4891
SARIMAX(3,1,2)(1,1,0)	2,9897	2,1298	3,8345
SARIMAX-NEURAL	2,9857	2,1269	3,8347

FONTE: o autor (2019)

Da TABELA 29, se observa que as estatísticas de aderência *MAE*, *MAPE* e *RMSE*, das previsões pelo método híbrido proposto foram menores do que as mesmas estatísticas de previsões dos métodos individuais na RD-D013-5, além destas mesmas estatísticas serem menores no ajuste dos respectivos métodos preditivos.

Ao considerar a influência da temperatura ambiente sobre as deformações corrigidas do concreto, as previsões pelo método híbrido tiveram melhor precisão

com ganho entre 18% e 37%, confirmando que de fato a temperatura ambiente influencia nas deformações corrigidas do concreto. O fato de não haver ganho percentual em relação ao SARIMAX indica que os dados de deformação do concreto e da temperatura ambiente possuem, predominantemente, estrutura de dependência linear nesta roseta.

TABELA 30 - COMPARAÇÃO DOS GANHOS PREDITIVOS PERCENTUAIS DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS DA RD-D013-5

MÉTODOS INDIVIDUAIS	MÉTODO SARIMAX-NEURAL		
	MAE	MAPE	RMSE
SARIMA	24,25%	24,75%	18,91%
RNN DL-LSTM	37,15%	37,58%	30,14%
SARIMAX	0,00%	0,00%	0,00%

FONTE: O autor (2019)

Este procedimento para obtenção dos métodos preditivos, as respectivas predições e as estatísticas de aderência, das séries temporais das deformações corrigidas do concreto da roseta RD-D013-5, foi repetido para os demais braços da respectiva roseta. Na TABELA 31 são apresentadas as medidas de aderência MAE, MAPE e RMSE para comparação da precisão preditiva do método híbrido com os respectivos métodos individuais, SARIMA, RNN DL-LSTM e SARIMAX para os braços 1, 2, 3 e 4 da roseta RD-D013.


TABELA 31 - COMPARAÇÃO DAS ACURÁCIAS DAS PREDIÇÕES POR DIFERENTES MÉTODOS PREDITIVOS PARA OS BRAÇOS 1, 2, 3 E 4 DA ROSETA RD-D013

MÉTODO	ROSETA RD-D013-1			MÉTODO	ROSETA RD-D013-2		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(5,1,4)(2,1,0)	3,42	1,62	3,96	SARIMA(4,1,5)(2,1,0)	2,95	1,67	3,57
RNN DL-LSTM	5,60	2,66	6,10	RNN DL-LSTM	4,87	2,86	5,84
SARIMAX(4,1,3)(1,1,1)	2,93	1,42	3,85	SARIMAX(1,1,0)(1,1,0)	2,55	1,50	3,07
SARIMAX-NEURAL	2,89	1,40	3,85	SARIMAX-NEURAL	2,47	1,45	3,02
MÉTODO	ROSETA RD-D013-3			MÉTODO	ROSETA RD-D013-4		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
SARIMA(5,1,3)(2,1,1)	4,04	1,57	4,82	SARIMA(3,1,1)(1,1,0)	6,17	2,08	7,83
RNN DL-LSTM	6,48	2,49	7,36	RNN DL-LSTM	5,80	1,96	7,64
SARIMAX(4,1,2)(1,1,1)	3,54	1,38	4,56	SARIMAX(3,1,1)(1,1,1)	5,21	1,76	6,06
SARIMAX-NEURAL	3,52	1,38	4,56	SARIMAX-NEURAL	5,14	1,73	6,01

FONTE: O autor (2019)

Na FIGURA 54 são apresentadas partes das séries das deformações corrigidas do concreto e as respectivas previsões pelo método híbrido SARIMAX-NEURAL e pelos métodos individuais, SARIMA, RNN DL-LSTM e SARIMAX para os braços 1, 2, 3 e 4 da roseta RD-D013.

FIGURA 54 – DADOS DE DEFORMAÇÃO E PREDIÇÕES DE QUATRO BRAÇOS DA ROSETA RD-D013 VIA MÉTODOS SARIMA, RNN DL-LSTM, SARIMAX E SARIMAX-NEURAL




FONTE: O autor (2019)

Na análise do comportamento das deformações do concreto, pela projeção futura da curva de tendência da série temporal, da roseta RD-D013-5 a partir das previsões feitas pelo método híbrido SARIMAX-NEURAL, se observa que a projeção futura da tendência da referida série também seguiu a tendência da série original. É importante destacar que a série temporal RD-D013-5 tem uma tendência crescente, assim como apresentou uma mudança de regime no segundo semestre de 2003. Isto significa dizer que esta tendência não é assintótica e também não foram obtidas informações técnicas sobre as possíveis causas desta mudança de regime, porém, pode-se dizer que a partir do ano de 2003 as deformações da roseta RD-D013 tiveram tendência de comportamento assintótico ao longo tempo.

A FIGURA 55 apresenta os respectivos gráficos da série original da roseta RD-D013-5, a curva de tendência, as previsões pelo método híbrido e a projeção futura da tendência de acordo com as respectivas previsões.

FIGURA 55 – DADOS, PREDIÇÕES E PROJEÇÃO FUTURA DA TENDÊNCIA DA SÉRIE TEMPORAL DAS DEFORMAÇÕES CORRIGIDAS DO CONCRETO DA ROSETA RD-D013-5



FONTE: O autor (2019)

No âmbito geral, a TABELA 32 mostra a comparação percentual das estatísticas de aderência (*MAE*, *MAPE*, *RMSE*) do método híbrido em relação aos métodos individuais para as 25 séries temporais modeladas das 5 rosetas, conforme os valores médios da última linha TABELA 33. Uma vez que o método híbrido considera a influência da variável exógena (temperatura ambiente) na modelagem, foi obtido um ganho preditivo em relação aos modelos de redes neurais RNN DL-LSTM e ao SARIMA, em que a modelagem foi realizada apenas sobre os dados de deformação do concreto.

TABELA 32 - COMPARAÇÃO DO GANHO PREDITIVO MÉDIO EM PORCENTAGEM DO MÉTODO HÍBRIDO EM RELAÇÃO AOS MÉTODOS INDIVIDUAIS

Métodos Individuais	Método SARIMAX-NEURAL		
	MAE	MAPE	RMSE
RNN DL-LSTM	35,41%	33,26%	32,33%
SARIMA	37,72%	29,07%	35,30%
SARIMAX	13,11%	10,79%	11,34%

FONTE: O Autor (2019)

Em relação ao SARIMAX o ganho preditivo percentual médio do método híbrido foi devido a modelagem dos resíduos do modelo SARIMAX, via rede recorrente RNN DL-LSTM.

TABELA 33 - COMPARAÇÃO DA PRECISÃO DAS ESTATÍSTICAS DE ADERÊNCIA MAE, MAPE E RMSE DOS MÉTODOS PREDITIVOS DAS 25 SÉRIES TEMPORAIS MODELADAS DO BLOCO D57


Roseta/ Braço	RNN DL-LSTM			SARIMA(p,d,q)(P,D,Q)				SARIMAX(p,d,q)(P,D,Q)				SARIMAX-NEURAL		
	MAE	MAPE	RMSE	parâmetros	MAE	MAPE	RMSE	parâmetros	MAE	MAPE	RMSE	MAE	MAPE	RMSE
RD-09/1	8,66	1,81	9,39	(2,2,3)(0,0,2)	8,34	1,74	9,10	(4,2,3)(0,1,1)	7,31	1,52	7,98	4,51	0,94	5,16
RD-09/2	5,70	0,87	7,26	(4,2,5)(1,1,0)	16,82	2,59	18,83	(0,2,1)(1,1,1)	8,52	1,31	9,80	6,92	1,06	7,86
RD-09/3	7,95	1,39	9,38	(2,2,4)(1,1,0)	17,26	3,06	19,34	(0,2,1)(1,1,1)	8,39	1,49	9,79	5,90	1,04	6,83
RD-09/4	4,03	1,03	4,64	(5,2,4)(0,0,1)	13,06	3,32	14,85	(4,2,3)(0,1,2)	3,75	0,95	4,51	3,28	0,83	4,03
RD-09/5	8,58	1,53	9,71	(2,2,2)(1,1,0)	7,78	1,39	9,68	(4,1,4)(1,1,1)	6,44	1,14	7,04	5,47	0,96	6,29
RD-010/1	4,27	4,37	4,70	(2,1,3)(1,1,0)	4,99	5,16	6,25	(1,1,0)(2,1,1)	3,69	3,81	4,83	3,71	3,83	4,84
RD-010/2	3,20	2,05	4,64	(1,1,0)(1,1,0)	4,29	2,83	5,82	(2,1,1)(1,1,1)	2,69	1,77	3,69	2,70	1,78	3,70
RD-010/3	5,93	3,24	7,71	(3,0,3)(1,1,0)	4,25	2,37	4,99	(4,1,3)(1,1,1)	4,10	2,31	5,12	3,98	2,24	4,98
RD-010/4	2,34	1,88	2,81	(3,0,3)(1,1,0)	3,98	3,20	4,73	(3,1,3)(1,0,1)	4,40	3,60	5,48	4,37	3,58	5,47
RD-010/5	4,79	3,57	5,60	(2,0,3)(1,1,0)	4,13	3,09	4,94	(2,1,1)(1,1,1)	4,21	3,17	5,11	3,91	2,94	4,94
RD-011/1	5,35	2,52	6,24	(4,1,2)(1,0,1)	2,98	1,43	3,95	(4,1,2)(1,1,1)	2,94	1,40	3,30	2,94	1,40	3,30
RD-011/2	5,21	3,00	5,88	(3,1,1)(1,1,0)	5,62	3,25	6,12	(2,1,2)(1,1,1)	2,71	1,58	3,24	1,88	1,09	2,38
RD-011/3	7,21	4,21	8,93	(4,0,3)(1,1,0)	3,21	1,93	4,61	(3,1,1)(1,0,1)	4,13	2,42	4,99	2,22	1,32	2,60
RD-011/4	2,74	1,35	3,62	(3,1,2)(1,1,0)	4,50	2,19	5,20	(3,1,4)(1,0,1)	2,02	0,98	2,47	1,89	0,92	2,37
RD-011/5	2,38	1,79	3,13	(1,1,2)(1,0,0)	2,33	1,76	3,10	(0,1,1)(2,1,1)	3,54	2,68	4,48	1,87	1,42	3,02
RD-012/1	5,57	2,04	6,96	(2,1,1)(1,1,0)	3,86	1,43	5,81	(1,1,0)(2,1,1)	3,47	1,28	5,29	3,51	1,30	5,32
RD-012/2	7,40	3,67	8,25	(1,1,0)(1,1,0)	5,88	2,92	7,21	(2,1,1)(1,0,0)	5,55	2,77	6,93	5,49	2,74	6,87
RD-012/3	13,19	4,73	13,81	(3,0,3)(1,1,0)	5,26	1,88	5,97	(4,1,3)(1,1,1)	3,76	1,35	4,46	3,67	1,31	4,42
RD-012/4	6,07	1,73	7,68	(2,1,1)(1,1,0)	4,13	1,18	4,97	(1,1,2)(1,1,1)	3,01	0,86	3,62	2,96	0,85	3,58
RD-012/5	3,88	2,15	4,44	(2,0,3)(1,1,0)	3,10	1,73	3,62	(2,1,1)(1,1,1)	3,01	1,68	3,47	2,81	1,57	3,20
RD-013/1	4,74	2,21	5,25	(5,1,4)(2,1,0)	3,42	1,62	3,96	(4,1,3)(1,1,1)	2,93	1,42	3,85	2,89	1,40	3,85
RD-013/2	4,87	2,86	5,84	(4,1,5)(2,1,0)	2,95	1,67	3,57	(1,1,0)(1,1,0)	2,55	1,50	3,07	2,47	1,45	3,02
RD-013/3	6,48	2,49	7,36	(5,1,3)(2,1,1)	4,04	1,57	4,82	(4,1,2)(1,1,1)	3,54	1,38	4,56	3,52	1,38	4,56
RD-013/4	5,80	1,96	7,64	(3,1,1)(1,1,0)	6,17	2,08	7,83	(3,1,1)(1,1,1)	5,21	1,76	6,06	5,14	1,73	6,01
RD-013/5	4,75	3,41	5,49	(3,0,2)(1,1,0)	3,94	2,83	4,73	(3,1,2)(1,1,0)	2,99	2,13	3,83	2,99	2,13	3,83
MÉDIA GERAL	5,64	2,47	6,65		5,85	2,33	6,96		4,19	1,85	5,08	3,64	1,65	4,50

FONTE: O autor (2019)

Sobre o tema desta tese, Ribeiro et al. (2019) publicaram um trabalho na revista *Engineering Structures*. Os autores destacaram a importância da modelagem para predição de dados reais, das deformações corrigidas do concreto influenciadas pela temperatura ambiente por meio de um método híbrido, como subsídio no auxílio preventivo à equipe técnica na segurança de barragem.

A FIGURA 56 apresenta de forma resumida os valores médios das estatísticas de aderência MAE, MAPE e RMSE em relação a cada método para as 25 séries temporais modeladas das 5 rosetas de deformímetro do bloco de contraforte D57. Estes valores correspondem a última linha da TABELA 33 e foram utilizados para calcular os ganhos percentuais preditivos do método SARIMAX-NEURAL em relação aos métodos individuais da TABELA 32.

FIGURA 56 - COMPARAÇÃO DOS VALORES MÉDIOS DAS ESTATÍSTICAS MAE, MAPE E RMSE PARA AS 25 SÉRIES TEMPORAIS DAS 5 ROSETAS DO BLOCO D57



FONTE: O autor (2019)

5 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentado o método híbrido denominado SARIMAX-NEURAL para predição de séries temporais, medidas por rosetas de deformímetro instaladas em um bloco de concreto de contraforte na usina hidrelétrica de Itaipu. O respectivo método híbrido foi definido como a combinação linear (soma) dos métodos SARIMAX, para predizer as deformações corrigidas do concreto influenciadas pela temperatura ambiente, e redes neurais recorrentes *Deep Learning* com arquitetura *LSTM* (RNN DL-LSTM) aplicado aos resíduos do método SARIMAX.

Foram realizadas as modelagens de predição dos métodos SARIMA e RNN DL-LSTM, individualmente, sem considerar a influência da temperatura ambiente na modelagem, isto é, a modelagem foi apenas das séries temporais das deformações corrigidas do concreto. Isto para comparar a influência da temperatura ambiente nas deformações corrigidas do concreto. Tal comparação foi realizada por meio das estatísticas de aderência *MAE*, *MAPE* e *RMSE* (que medem a precisão de predição ou os erros dos métodos).

Este trabalho teve como objetivos principais fazer as predições das deformações corrigidas do concreto, influenciadas pela temperatura ambiente, por meio do método híbrido; comparar com as predições dos métodos individuais SARIMA e RNN DL-LSTM, nos quais não foi considerado o efeito da temperatura ambiente e construir os intervalos de predição das deformações via *Bootstrap*.

De forma resumida, no âmbito geral, ao considerar o efeito da temperatura ambiente sobre as deformações corrigidas do concreto, as predições obtidas pelo método híbrido proposto obtiveram melhor precisão de predição em relação aos métodos SARIMA e RNN DL-LSTM.

Como conclusão pode-se afirmar que pela melhor precisão de predição do método híbrido em relação aos métodos individuais, de fato a temperatura ambiente tem influência sobre as deformações corrigidas do concreto, isto foi confirmado pelo ganho preditivo percentual entre 29% e 37%.

Já na comparação do método híbrido SARIMAX-NEURAL com o método SARIMAX, o ganho preditivo ficou entre 10% e 13%. Neste caso, a melhor precisão de predição foi devido à modelagem dos resíduos do SARIMAX por meio da rede neural recorrente RNN DL-LSTM, uma vez que a predição do método híbrido foi

definida como a soma da predição do SARIMAX com a predição do RNN DL-LSTM dos resíduos do SARIMAX.

Desta forma se confirmou que a combinação de métodos preditivos possibilitou melhor precisão preditiva, pelas estatísticas de aderência *MAE*, *MAPE* e *RMSE*, em relação as predições dos métodos individualmente, como indicado na literatura.

É importante destacar que o método híbrido proposto foi aplicado e testado sua eficiência em dados reais de deformação do concreto, em que as respectivas séries temporais apresentaram sazonalidade e também com estrutura de auto dependência linear e não linear. Destaca-se também que o referido método híbrido pode ser aplicado para predição de outros tipos de instrumentos que medem diferentes fenômenos do concreto, assim como, é aplicável em outras áreas da engenharia.

Também foi realizada análise do comportamento das deformações do concreto a partir da curva de tendência e sua projeção futura. Pela RD-D09 foi observado que o comportamento da curva de tendência, indicando que as deformações do concreto têm comportamento estável nesta roseta. Na roseta RD-D010 também foi observado que a curva de tendência desta série e sua projeção futura tiveram comportamento estável, isto indicou que as deformações corrigidas do concreto seguiram comportamento assintótico, embora houvesse oscilação convexa nesta roseta.

As rosetas RD-D011 e RD-D012, que estão na base da barragem, apresentaram tendência crescente e também mudança de regime em determinado tempo. As respectivas curvas de tendência e suas projeções indicaram que as deformações foram crescentes ao longo do tempo, indicando que nestas rosetas as deformações corrigidas do concreto não tiveram comportamento assintótico.

A roseta RD-D013 também apresentou mudança de regime no segundo semestre de 2003 e ainda os dados mostraram que não houve deformação elástica no início das medições como nas outras rosetas. Neste caso, séries tiveram tendência crescente, embora a partir de 2003, quando houve mudança de regime, indique tendência assintótica. Nesta roseta ocorre a maior incidência solar, uma vez que está localizada a jusante da barragem. A temperatura ambiente pode ser considerada uma causa da não ocorrência de deformação elástica nas deformações

corrigidas do concreto, nesta roseta, e também pode ser considerado um dos fatores do comportamento da curva de tendência não ser assintótico.

Com vistas a melhor precisão de predição obtidas nesta tese são propostas algumas sugestões para trabalhos futuros:

- i) Utilizar uma combinação linear com pesos diferentes para a soma das predições dos métodos que compõe o método híbrido;
- ii) Fazer uma combinação não linear para compor a forma de predição dos respectivos métodos;
- iii) Utilizar outras funções de ativação, além da tangente hiperbólica usada neste trabalho, na camada oculta da arquitetura *LSTM* das redes neurais recorrentes *Deep Learning*, para obter melhor precisão de predição;
- iv) Nesta tese foram modeladas as deformações corrigidas do concreto, assim, é sugerido o estudo das deformações puras, que são medidas pelos deformímetros, com o objetivo de auxílio mais eficiente à equipe técnica da segurança de barragem.

6 REFERÊNCIAS

ABNT. NBR 6118 -Projeto de Estruturas de Concreto - Procedimento. **Associação Brasileira de Normas Técnicas**, 2004. Rio de Janeiro: Associação Brasileira de Normas Técnicas.

ABURTO, L.; WEBER, R. Improved Supply Chain Management Based on Hybrid Demand Forecasts. **Applied Soft Computing Journal**, v. 7, n. 1, p. 136–144, 2007.

ACI209.2-R08. Guide for Modeling and Calculating Shrinkage and Creep in Hardened Concrete. **American Concrete Institute**, 2008.

ACI209R-R92, A. C. I. Prediction of creep , shrinkage and temperature effects in concrete sturutres. , 1992.

ANDRIOLO, F. R.; SGARBOZA, C. B. **Inspeção e Controle de Qualidade do Concreto**. São Paulo: NewsWork, 1993.

ARAÚJO, J. M. DE. Estruturas de Concreto: Modelos de Previsão da Fluência e da Retração do Concreto. **Dunas**, 2002. Rio Grande.

AWRUCH, A. M.; GOMES, H. M. Análise da Confiabilidade de Estruturas de Concreto Armado com uma Metodologia para Inclusão de Efeitos Estocásticos de Propriedades dos Materiais. **Revista Internacional de Metodos Numericos para Calculo y Diseno en Ingenieria**, v. 30, n. 2, p. 85–96, 2014.

BABU, C. N.; REDDY, B. E. A Moving-Average Filter Based Hybrid ARIMA–ANN Model for Forecasting Time Series Data. **Applied Soft Computing**, v. 23, p. 27–38, 2014.

BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. **Journal of the Operational Research Society**, v. 20, n. 4, p. 451–468, 1969.

BAŽANT, Z. P. Material Models for Structural Creep Analysis. **Mathematical Modeling of Creep en Shrinkage of Concrete**. p.59, 1988. Illinois, USA.

BAŽANT, Z. P.; BAWEJA, S. Creep and Shrinkage Prediction Model for Analysis and Design of Concrete Structures : Model B3. **Adam Neville Symposium: Creep and Shrinkage—Structural Design Effects**, v. 83, p. 38–39, 2000.

BENGIO, Y. **Learning Deep Architectures for AI**. Montreal: Foundations and Trends, 2009.

BOX, G. E. P.; COX, D. R. An analysis of Transformations: Applying the Box-Cox Transformation. **Journal of the Royal Statistical Society**, v. Series B, n. 26, p. 211–252, 1964.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. Oakland, 1976.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. Englewood Cliffs, NJ: 3 ed, Prentice Hall, 1994.

BOX, G.; PIERCE, D. Distribution of Residual Autocorrelations in Autoregressive Integrated moving Average Time Series Models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509–1526, 1970.

CASSIANO, K. M. **Análise de Séries Temporais Usando Análise Espectral Singular (SSA) e Clusterização de Suas Componentes Baseada em Densidade**, 2014. Pontifícia Universidade Católica do Rio de Janeiro - PUCRJ.

CEN, 1992-1-1. Eurocódigo 2: Projeto de Estruturas de Concreto - Parte 1-1: Regras Gerais e Regras para Edifícios. , p. 245, 2004.

CLEMEN, R. T. Combining forecasts: A review and annotated bibliography. **International Journal of Forecasting**, v. 5, n. 4, p. 559–583, 1989.

COSTA NETO, R. C. D. F. Estudo Experimental Sobre os Efeitos da Fluência do Concreto em Pilares Esbeltos. , 2004.

DAVISON, A. C.; HINKLEY, D. V. **Bootstrap Methods and Their Application**. Cambridge series in statistical and probabilistic mathematics, 1997.

DELEEUW, J. Introduction to Akaike Information Theory and an Extension of the Maximum Likelihood Principle. **Breakthroughs in Statistics Volume I: Foundations and Basic Theory**, 1973.

DELSAUTE, B.; TORRENTI, J. M.; STAQUET, S. Modeling basic creep of concrete since setting time. **Cement and Concrete Composites**, v. 83, p. 239–250, 2017.

DICKEY, D. A.; SAID, E. S. Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order. **Oxford Journals**, v. 71, n. 3, p. 599–607, 1984.

DINIZ, C.; LOUZADA, F.; DINIZ, C.; UFSCAR, D.; LOUZADA, F. Métodos Estatísticos para Análise de Dados de Crédito. , 2013.

DURBIN, J.; WATSON, G. S. Testing for Serial Correlation in Least Squares Regression II. **Biometrika**, v. 37, n. 3–4, p. 409–428, 1950.

EFRON, B. Bootstrap Methods: Another Look at the Jackknife. **The Annals of Statistics**, v. 7, n. 1, p. 26, 1979.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. 1º ed. Chapman and Hall/CRC, 1994.

ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987–1008, 1982.

EQUIPE DE FURNAS. **Concretos: Massa, Estrutural, Projetado e Compactado com Rolo - Ensaios e Propriedades**. São Paulo: Pini, 1997.

FARIA, A. E.; MUBWANDARIKWA, E. The Geometric Combination of Bayesian Forecasting Models. **Journal of Forecasting**, v. 27, n. 6, p. 519–535, 2008.

GARDNER, N. J. Comparison of prediction drying shrinkage and creep of normal-strength concrete. , v. n. 31, p. 8, 2004.

GOLYANDINA, N. On the Choice of Parameters in Singular Spectrum Analysis and Related Subspace-Based Methods. **Statistics and Its Interface**, v. 3, p. 32, 2010.

GOLYANDINA, N.; NEKRUTKIN, V.; ZHIGLJAVSKY, A.; et al. **Analysis of Time Series Structure**. New York: Chapman and Hall/CRC., 2001.

GRANGER, C. W. J. Combining Forecasts-Twenty Years Later. **Journal of Forecasting**, v. 8, p. 167–173, 1989.

GRANGER, C. W. J.; RAMANATHAN, R. Improved Methods of Forecasting. **Journal of Forecasting**, v. 3, p. 197–204, 1984.

GRAVES, A. **Supervised Sequence Labelling with Recurrent Neural Networks**. Toronto: Springer, Studies in Computational Intelligence, 2012.

GUPTA, S.; WILTON, P. C. Combination of Forecasts: An Extension. **Management Science**, v. 33, n. 3, p. 356–372, 1987.

HAMILTON, J. D. Time Series Analysis. **Princeton University Press**, 1994.

HAN, B.; XIE, H. B.; ZHU, L.; JIANG, P. Nonlinear Model for Early Age Creep of Concrete Under Compression Strains. **Construction and Building Materials**, v. 147, p. 203–211, 2017.

HASSANI, H. Singular Spectrum Analysis: Methodology and Comparison. **Journal of Data Science**, v. 5, p. 239–257, 2007.

HAYKIN, S. Redes neurais: princípios e prática. **Bookman**, p. 900, 2001.

HAZEWINKEL, M. **Spline Interpolation**. 2001.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 1997.

INPE. Sistema Integrado de Dados Ambientais. , 2017.

ITAIPU, U. H. Projeto: Aspectos de engenharia. **Realização da diretoria técnica da Itaipu Binacional, Coordenação geral da Superintendência de engenharia da Itaipu Binacional**, p. 784, 2009.

KALINTZIS, C. A. A. Estudo da Fluência do Concreto de Elevado Desempenho. **Escola Politécnica da Universidade de São Paulo**, 2000. São Paulo.

KATAOKA, L. T. **Estudo Experimental e Numérico da Deformabilidade por Fluência e sua Utilização na Monitoração de Estruturas de Concreto**, 2010. São Paulo: Universidade de São Paulo.

KHOSRAVI, A.; NAHAVANDI, S.; SRINIVASAN, D.; KHOSRAVI, R. Constructing Optimal Prediction Intervals by Using Neural Networks and Bootstrap Method. **IEEE Transactions on Neural Networks and Learning Systems**, v. 26, n. 8, p. 1810–1815, 2015.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. **Biological Cybernetics**, v. 43, n. 1, p. 59–69, 1982.

KUBRUSLY, C. S. **Elements of Operator Theory**. Boston: Birkhäuser, Boston, 2001.

KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SCHMIDT, P.; SHIN, Y. Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root. **Journal of Econometrics**, v. 54, n. 1–3, p. 159–178, 1992.

LJUNG, G. M.; BOX, G. E. On a Measure of Lack of Fit in Time Series Models. **Biometrika**, v. 65, n. 2, p. 297–303, 1978.

LOCKMAN, N. J. G. AND M. J. Design Provisions for Drying Shrinkage and Creep of Normal-Strength Concrete. **American Concrete Institute**, v. 98, n. 2, p. 159–167, 2001.

LUTTERKORT, D.; PETERS, J. Linear Envelopes for Uniform B-spline Curves.

Proceedings, v. 1, p. 1–7, 1999.

MAKRIDAKIS, S.; WINKLER, R. L. Averages of Forecasts: Some Empirical Results. **Management Science**, v. 29, n. 9, p. 987–996, 1983.

MARKOWITZ, H. A Logical Calculus of the Ideas Immanent in Nervous Activity. **The Journal of Finance**, v. 7, n. 1, p. 77–91, 1952.

MATOS, S. F. **Avaliação de Instrumentos para Auscultação de Barragem de Concreto. Estudo de Caso: Deformímetros e Tensômetros para Concreto na Barragem de Itaipu**, 2002. Universidade Federal do Paraná.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus Nervous Activity. **Bulletin of Mathematical Biology**, v. 52, n. 1, p. 99–115, 1990.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto: Estrutura, Propriedades e Materiais**. Pini, 1994.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto Microestrutura, Propriedades e Materias**. 2º ed. São Paulo: Pini, 2008.

MORETTIN, P. A.; TOLOI, C. M. DE C. **Modelos para Previsão de Séries Temporais V.1**. Rio de Janeiro: IMPA - Instituto de Matemática Pura e Aplicada, 1981.

MORETTIN, P. A.; TOLOI, C. M. DE C. **Análise de Séries Temporais**. , 2006.

MULGREW, B. Applying radial basis functions. **Signal Processing Magazine, IEEE**, v. 13, n. 2, p. 50–65, 1996.

NEVILLE, A. M. **Properties of Concrete**. 5º ed. Pearson, 2011.

NUNES, N. L.; FIGUEIREDO, A. D. **Retração do Concreto de Cimento Portland**. São Paulo: Boletim Técnico da Escola Politécnica da USP, 2007.

PAN, L.; POLITIS, D. N. Bootstrap prediction intervals for linear, nonlinear and nonparametric autoregressions. **Journal of Statistical Planning and Inference**, v. 177, p. 1–27, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S037837581400175X>. .

PICKETT, G. The Effect of Change in Moisture Content on the Creep of Concrete Under a Sustained Load. **ACI Journal**, v. 38, n. 333–56, 1942.

PICKETT, G. Effect of Aggregate on Shrinkage of Concrete and a Hypothesis Concerning Shrinkage. **ACI Journal**, v. 52, n. 1, p. 581–590, 1956. Chicago.

RIBEIRO, L. DA S.; WILHELM, V. E.; FARIA, É. F. DE; SANTOS, A. C. P.; RODRIGUES, S. B. Modelagem Sarima Aplicada na Predição das Deformações Diferidas do Concreto em Barragem de Contraforte. **60 Congresso Brasileiro do Concreto - IBRACON**, 2018. Foz do Iguaçu - PR: Anais 60 IBRACON.

RIBEIRO, L. S.; WILHELM, V. E.; FARIA, É. F.; CORREA, J. M.; DOS SANTOS, A. C. P. A comparative analysis of long-term concrete deformation models of a buttress dam. **Engineering Structures**, v. 193, p. 301–307, 2019. Elsevier. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0141029618336617>. .

ROBINSON, A. J.; FALLSIDE, F. The Utility Driven Dynamic Error Propagation. , 1987. Denver: Cambridge University Engineering Department.

RODRIGUES, S. B. **Método híbrido interativo sarima support vector regression wavelet de múltiplos núcleos na previsão de séries temporais de instrumentos de barragens**, 2015. Universidade Federal do Paraná - UFPR.

ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

RUGGIERO, M. A G.; LOPES, V. L. D. R. **Calculo Numérico Aspectos Teóricos e Computacionais**. 2º ed. São Paulo: Pearson, 1998.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Representations by Back-Propagating Errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

SANTOS, H. C. UM MODELO CONSISTENTE PARA REPRESENTAÇÃO DA DEFORMAÇÃO LENTA DO CONCRETO. , p. 1–10, 2002.

SCHMIDHUBER, J. **Deep Learning in Neural Networks: An Overview**. 2014.

SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Statistics**, v. 6, n. 2, p. 461–464, 1978.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality(Complete Samples). **Biometrika**, v. 52, n. 3, p. 591–611, 1965.

SLUTZKY, E. The Summation of Random Causes as the Source of Cyclic Processes. **Econometrica**, v. 5, n. 2, p. 105–146, 1937.

STANTON, JEFFREY, M. Galton, Pearson, and the Peas: A Brief History of Linear Regression for Statistics Instructors. **Journal of Statistics Education**, v. 9, n. 3, 2001.

TAFNER, M. A. **Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação**. Blumenau: EKOS, 1996.

TEIXEIRA JÚNIOR, L. A. **Combinação SSA-Wavelet de Métodos Preditivos com Ajuste Numérico MINIMAX , na Geração de Previsões**, 2013. Pontifícia Universidade Católica do Rio de Janeiro.

TEIXEIRA, R. R. **Modelagem por elementos finitos para análise de tensões e deformações por fluência no concreto compactado com rolo**. 2006.

TIBSHIRANI, R. A Comparison of Some Error Estimates for Neural Network Models. **Neural Computation**, v. 8, n. 1, p. 152–163, 1996. MIT Press.

VIDELA, C. C. Modeling drying shrinkage of hardened chilean concretes. In: II SIMPÓSIO IBER-AMERICANO SOBRE CONCRETO ESTRUTURA. Anais SIABE 06. , 2006.

WALLIS, K. F. Combining Forecasts - Forty Years Later. **Applied Financial**

Economics, v. 21, n. 1, p. 33–41, 2011.


WERBOS, P. J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. **Harvard University**, 1974.

ZHANG, G. P. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. **Neurocomputing**, v. 50, p. 159–175, 2003.

ZHENG, F.; ZHONG, S. Time Series Forecasting using A Hybrid RBF Neural Network and AR Model Based on Binomial Smooting. **World Academy of Science, Engineering and Technology**, v. 51, p. 1464–1468, 2011.


7 APÊNDICES

APÊNDICE I A: Dados de teste das deformações corrigidas do concreto, previsões e intervalos de confiança das previsões dos braços 1, 2, 3 e 4 da roseta RD-D09.




FONTE: O Autor (2019)

APÊNDICE II A: Dados de teste das deformações corrigidas do concreto, previsões e intervalos de confiança das previsões dos braços 1, 2, 3 e 4 da roseta RD-D010.




FONTE: O Autor (2019)

APÊNDICE III A: Dados de teste das deformações corrigidas do concreto, previsões e intervalos de confiança das previsões dos braços 3, 4 e 5 da roseta RD-D011.




FONTE: O Autor (2019)

APÊNDICE IV A: Dados de teste das deformações corrigidas do concreto, previsões e intervalos de confiança das previsões dos braços 3, 4 e 5 da roseta RD-D012.



FONTE: O Autor (2019)

APÊNDICE V A: Dados de teste das deformações corrigidas do concreto, previsões e intervalos de confiança das previsões dos braços 1, 2, 3, e 4 da roseta RD-D013.



FONTE: O Autor (2019)

APÊNDICE I B: Tabela que apresenta a comparação percentual das estatísticas de aderência MAE, MAPE e RMSE, para as previsões fora da amostra de treinamento, entre o método híbrido e os demais métodos individuais. Esta comparação foi realizada por roseta.

Método	RD-D09 SARIMAX-NEURAL			Método	RD-D010 SARIMAX-NEURAL		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
RNN DL-LSTM	25.29%	26.93%	25.30%	RNN DL-LSTM	9.12%	4.99%	5.94%
SARIMA	58.77%	59.99%	57.99%	SARIMA	13.76%	13.76%	10.44%
SARIMAX	24.20%	24.47%	22.88%	SARIMAX	2.25%	2.05%	1.17%
Método	RD-D011 SARIMAX-NEURAL			Método	RD-D012 SARIMAX-NEURAL		
	MAE	MAPE	RMSE		MAE	MAPE	RMSE
RNN DL-LSTM	52.84%	52.29%	50.87%	RNN DL-LSTM	48.56%	45.22%	42.81%
SARIMA	42.14%	41.81%	40.56%	SARIMA	16.45%	14.12%	14.68%
SARIMAX	29.71%	32.28%	26.11%	SARIMAX	1.19%	1.26%	1.00%
Método	RD-D013 SARIMAX-NEURAL						
	MAE	MAPE	RMSE				
RNN DL-LSTM	36.14%	37.36%	32.61%				
SARIMA	17.08%	17.11%	14.60%				
SARIMAX	1.23%	1.18%	0.49%				

FONTE: O Autor (2019)

8 ANEXOS

Neste anexo estão descritos os modelos empíricos para modelagem das curvas deformação por fluência do concreto, coeficientes de fluência e também as curvas de deformação por retração do concreto. Estes são modelos consagrados da literatura.

8.1 MODELO B3

O modelo B3, apresentado por Bazănt e Baweja (2000), é um dos modelos para predição da fluência do concreto, admitindo que esta seja linearmente dependente da tensão e está restrito as tensões de serviço da ordem de $0,45f'_c$ (resistência média à compressão). A fluência $J(t,t')$ é modelada por:

$$J(t,t') = q_1 + C_0(t,t') + C_d(t,t',t_0) \quad (38)$$

Em que, q_1 – Deformação instantânea devido à tensão unitária; $C_0(t,t')$ – Fluência básica (em $10^{-6}/\text{psi}$) e $C_d(t,t',t_0)$ – fluência por secagem.

A fluência básica é dada por:

$$C_0(t,t') = q_2 Q(t,t') + q_3 \ln[1 + (t-t')^n] + q_4 \ln\left(\frac{t}{t'}\right) \quad (39)$$

$$Q(t,t') = Q_f(t') \left[1 + \left(\frac{Q(t')}{Z(t,t')} \right)^{r(t')} \right]^{-1/r(t')} \quad (40)$$

$$r(t') = 1,7(t')^{0,12} + 8 \quad (41)$$

$$Z(t,t') = (t')^{-m} \ln[1 + (t-t')^n] \quad (42)$$

$$Q(t') = \left[0,086(t')^{2/9} + 1,21(t')^{4/9} \right]^{-1} \quad (43)$$

Com $n = 0,1$ e $m = 0,5$ sendo dependentes do tipo de material. q_1 , q_2 , q_3 e q_4 são coeficientes empíricos definidos por:

$$q_1 = 0,6 \cdot \frac{10^6}{E_{28}} \quad (44)$$

$$q_2 = 451,5 \cdot c^{0,5} (f')^{-0,9} \quad (45)$$

$$q_3 = 0,29(w/c)^4 \cdot q_2 \quad (46)$$

$$q_4 = 0,14(a/c)^{-0,7} \quad (47)$$

$$E_{28} = 57000 \cdot (f'_c)^{1/2} \quad (48)$$

$$f'_c = f_{ck} + 1200 \quad (49)$$

Sendo:

w/c – relação água cimento

c – consumo de água (lb/ft³)

t – idade do concreto (dias)

t' – idade do carregamento do concreto (dias)

t_0 – idade do início da secagem em dias (somente $t_0 \leq t'$ são considerados)

h – umidade relativa do ambiente em porcentagem ($0 \leq h \leq 1$)

a/c – relação agregado cimento

f'_c – resistência média à compressão (psi)

E_{28} – módulo de elasticidade do concreto aos 28 dias (psi)

A fluência por secagem é dada por:

$$C_d(t, t', t_0) = q_5 \left[e^{-8H(t)} - e^{-8H(t')} \right]^{1/2}$$

q_5 – é um coeficiente empírico; $H(t)$ – é a média espacial da umidade relativa dos poros no interior da seção transversal, dados por:

$$q_5 = 7,57 \cdot 10^5 (f'_c)^{-1} \left| \varepsilon_{sh\infty} \right|^{-0,6} \quad (50)$$

$$H(t) = 1 - (1 - h)S(t) \quad (51)$$

$S(t)$ – É função do tempo para retração, dada por:

$$S(t) = tgh \left(\sqrt{\frac{t - t_0}{\tau_{sh}}} \right) \quad (52)$$

τ_{sh} – retração ao meio tempo (dias) dado por:

$$\tau_{sh} = k_t (k_s D)^2 \quad (53)$$

$$k_t = 190,8 t_0^{-0,08} (f_c')^{-1/4} \quad (54)$$

D – é a espessura efetiva da seção transversal (em polegadas), definida por:

$$D = 2 \left(\frac{v}{s} \right) \quad (55)$$

v/s – relação entre volume por área de superfície (polegadas)

$\varepsilon_{sh\infty}$ – retração final dependente do tempo

Os coeficientes k_s (que depende da forma) e k_h (que depende da umidade relativa do ambiente em %) estão descritos na TABELA 34.

TABELA 34 - VALORES DE REFERÊNCIA DOS COEFICIENTES k_s E k_h

k_s	k_h
1,00 para uma laje infinita	$1 - h^3$ para $U \leq 0,08$
1,15 para um cilindro infinito	0,85
1,25 para um prisma quadrado infinito	-0,2 para $h = 1$ (expansão em água)
1,3 para uma esfera	Interpolar para $0,98 \leq h \leq 1$
1,35 para um cubo	

FONTE: Bazant e Baweja (2004)

O coeficiente de fluência é dado por:

$$\phi(t, t') = E(t') J(t, t') - 1 \quad (56)$$

$E(t')$ – É o módulo de elasticidade do concreto aos t dias (psi), definido por:

$$E(t') = E_{28} \cdot \left(\frac{t}{4 + 0,85t} \right)^{1/2} \quad (57)$$

Para o modelo B3 há uma atualização realizada pelos autores Bazant & Baweja considerando o efeito da temperatura. Neste caso, a função de fluência $J(t, t')$ é atualizada por:

$$J_a(t, t') = p_1 + p_2 \cdot F(t, t') \quad (58)$$

Em que $F(t, t')$ é a função de atualização da fluência dada por:

$$F(t, t') = C_0(t, t') + C_d(t, t', t_0) \quad (59)$$

Os coeficientes p_1 e p_2 são obtidos pelo método dos mínimos quadrados:

$$p_2 = \frac{n \sum (F_i J_i) - (\sum F_i)(\sum J_i)}{n \sum (F_i^2) - (\sum F_i)^2}; \quad p_1 = \bar{J} - p_2 \cdot \bar{F} \quad (60)$$

Em que \bar{J} é a média de todos os valores J_i e \bar{F} é a média de todos os valores de F_i .

A atualização da expressão da fluência básica é dada por:

$$C_o(t, t', T) = R_T \left[q_2 \cdot Q(t_T, t'_e) + q_3 \cdot \ln \left(1 + (t_T - t'_e)^n \right) + q_4 \cdot \ln \left(\frac{t_T}{t'_e} \right) \right] \quad (61)$$

$$R_T = \exp \left[\frac{U'_c}{R} \left(\frac{1}{T_0} - \frac{1}{T} \right) \right] \quad (62)$$

$$\frac{U'_c}{R} = 3418 \omega^{-0,27} (f'_c)^{0,54} \quad (SI) \quad (63)$$

Em que T_0 é a temperatura de referência absoluta; T é a temperatura absoluta e ω é o teor de água na massa do concreto (em kg/m³ no SI).

8.2 MODELO EUROCODE 2 (EC2) 2003

No modelo EC2 é um modelo, aceito como norma técnica europeia, CEN (2004), considera que a fluência do concreto seja linearmente dependente das tensões constantes e está restrito as tensões de serviço da ordem de $0,45 f_{ck}(t_0)$ (resistência média à compressão). A fluência $\varepsilon_{cc}(\infty, t_0)$, no tempo ($t = \infty$), é modelada por:

$$\varepsilon_{cc}(\infty, t_0) = \varphi(\infty, t_0) \left(\frac{\sigma}{E_c} \right) \quad (64)$$

$\varphi(\infty, t_0)$ – É o coeficiente de fluência no tempo infinito, σ – é a tensão aplicada (MPa) e E_c – É o módulo de elasticidade médio na idade considerada do concreto (MPa).

O coeficiente de fluência previsto, entre o tempo t e t_0 , em relação à deformação elástica aos 28 dias, é dado por:

$$\varphi(t, t_0) = \varphi_0 \beta_c(t, t_0) \quad (65)$$

φ_0 – Coeficiente de fluência fictício;

$\beta_c(t, t_0)$ – Coeficiente que define o desenvolvimento da fluência no tempo;

$$\varphi_0 = \varphi_{RH} \beta(f_{cm}) \beta(t_0) \quad (66)$$

$$\beta_c(t, t_0) = \left(\frac{t - t_0}{\beta_H + t - t_0} \right) \quad (67)$$

φ_{RH} – Fator que considera a umidade relativa;

$\beta(f_{cm})$ – Fator que considera a resistência média à compressão do concreto;

$\beta(t_0)$ – Fator que considera o efeito da idade da aplicação de carga no concreto;

t_0 – Idade de carregamento do concreto;

t – Idade do concreto (dias);

$$\varphi_{RH} = 1 + \frac{1 - \frac{RH}{100}}{0,1 \sqrt[3]{h_0}} \quad \text{para } f_{cm} \leq 35 \text{MPa} \quad (68)$$

$$\varphi_{RH} = \left(1 + \frac{1 - \frac{RH}{100}}{0,1 \sqrt[3]{h_0}} \alpha_1 \right) \alpha_2 \quad \text{para } f_{cm} \geq 35 \text{MPa} \quad (69)$$

RH – Umidade relativa do ambiente;

α_1 e α_2 – Coeficientes para considerar a influência da resistência do concreto;

h_0 – Espessura fictícia do elemento de concreto (mm);

f_{cm} – Resistência média à compressão aos 28 dias;

$$\alpha_1 = \left(\frac{35}{f_{cm}} \right)^{0,7} \quad (70)$$

$$\alpha_2 = \left(\frac{35}{f_{cm}} \right)^{0,2} \quad (71)$$

$$h_0 = \frac{2A_c}{u} \quad (72)$$

$$\beta(f_{cm}) = \frac{16,8}{\sqrt{f_{cm}}} \quad (73)$$

$$\beta(t_0) = \frac{1}{0,1 + t_0^{0,2}} \quad (74)$$

$$t_0 = t_{0,T} \left(\frac{9}{2 + t_{0,T}^{1,2}} + 1 \right)^\alpha \geq 0,5 \quad (75)$$

$t_{0,T}$ – Idade do concreto no carregamento ajustada com a temperatura (dias), de acordo com o coeficiente α ;

α - Coeficiente dependente do tipo de cimento, igual à:

- 1 para cimento tipo S;
- 0 para cimento tipo N;
- 1 para cimento tipo R;

A_c – Área da seção transversal da peça de concreto (mm²);

u – Perímetro externo da seção transversal em contato com o ar (mm);

A influência da variação da temperatura, no intervalo de 0 a 80°C, na maturidade do concreto pode ser identificada corrigindo a idade do concreto pela equação:

$$t_T = \sum_{i=1}^n e^{-\left(\frac{400}{[273 + T(\Delta t_i)]} - 13,65\right)} \cdot \Delta t_i \quad (76)$$

t_T – Idade do concreto ajustada com a temperatura e substitui t nas equações correspondentes (dias);

$T(\Delta t_i)$ – Temperatura do ambiente (°C) durante o intervalo Δt_i ;

Δt_i – Período em que a temperatura média diária do ambiente se manteve constante (dias).

A deformação total por retração (ε_{cs}) é composta por duas parcelas, deformação de retração por secagem (ε_{cd}) e deformação de retração autógena (ε_{ca}), definida por:

$$\varepsilon_{cs} = \varepsilon_{cd} + \varepsilon_{ca} \quad (77)$$

$$\varepsilon_{cd}(t) = \beta_{ds}(t, t_s) \cdot k_h \cdot \varepsilon_{cd,0} \quad (78)$$

$$\beta_{ds}(t, t_s) = \frac{t - t_s}{(t - t_s) + 0,04 \sqrt{h_0^3}} \quad (79)$$

$$\varepsilon_{cd,0} = 0,85 \left[(220 + 110 \alpha_{ds1}) e^{-\alpha_{ds2} \frac{f_{cm}}{f_{cm0}}} \right] 10^{-6} \beta_{RH} \quad (80)$$

$$\beta_{RH} = -1,55 \left[1 - \left(\frac{RH}{RH_0} \right)^3 \right] \quad (81)$$

$f_{cm0} - 10\text{MPa};$

$t_s -$ Idade do carregamento no início da secagem;

A TABELA 35 mostra os respectivos valores dos coeficientes α_{ds1} (Coeficiente que depende do tipo de cimento) e α_{ds2} (Coeficiente que depende do tipo de cimento).

TABELA 35 - VALORES DE REFERÊNCIA PARA OS COEFICIENTES α_{ds1} e α_{ds2}

α_{ds1}		α_{ds2}	
3	para cimento classe S	0,13	para cimento classe S
4	para cimento classe N	0,12	para cimento classe N
6	para cimento classe R	0,11	para cimento classe R

FONTE: CEN1992-1-1 (2004)

$RH_0 - 100\%$

$k_h -$ Coeficiente que depende da espessura h_0 de acordo é mostrado na TABELA 36.

TABELA 36 - VALORES DE k_h NA EQUAÇÃO (78)

h_0	k_h
100	1,0
200	0,85
300	0,75
≥ 500	0,70

FONTE: CEN 1992-1-1 (2004)

A deformação por retração autógena é definida pelas equações:

$$\varepsilon_{ca} = \beta_{as}(t) \varepsilon_{ca}(\infty) \quad (82)$$

$$\varepsilon_{ca}(\infty) = 2,5(f_{ck} - 10)10^{-6} \quad (83)$$

$$\beta_{as}(t) = 1 - \exp(-0,2t^{0,5}) \quad (84)$$

$$f_{ck} = f_{cm} - 8 \text{ para } 3 < t < 28 \text{ dias} \quad (85)$$

$$f_{ck}(t) = f_{ck} \text{ para } t \geq 28 \text{ dias} \quad (86)$$

$$f_{cm}(t) = \beta_{cc}(t) f_{cm} \quad (87)$$

$$\beta_{cc}(t) = \exp \left[s \cdot \left(1 - \left(\frac{28}{t} \right)^{1/2} \right) \right] \quad (88)$$

t – Idade do concreto (dias);

$f_{ck}(t)$ – Resistência característica à compressão do concreto em t dias (MPa);

f_{ck} – Resistência característica à compressão do concreto aos 28 dias (MPa);

$f_{cm}(t)$ – Resistência média à compressão do concreto em t dias (MPa);

f_{cm} – Resistência média à compressão do concreto aos 28 dias (MPa);

$\beta_{cc}(t)$ – Coeficiente que depende da idade do concreto em t dias;

s – Coeficiente que depende do tipo de cimento:

0,20 cimento classe CEM42,5R; CEM53,5N e CEM53,5R (classe R);

0,35 cimento classe CEM32,5R; CEM42,5N (classe N);

0,38 cimento classe CEM32,5N (classe S)

O módulo de elasticidade médio aos 28 dias (E_{cm}) para concretos agregados de quartzo é dado por:

$$E_{cm} = 22 \cdot \left(\frac{f_{cm}}{10} \right)^{0,3} \quad (89)$$

O módulo de elasticidade no tempo t (dias) é dado por:

$$E_{cm}(t) = \left(\frac{f_{cm}(t)}{f_{cm}} \right)^{0,3} E_{cm} \quad (90)$$

8.3 MODELO ACI 209R (2008)

O modelo ACI209.2-R08 (2008) é condicionado aos padrões de cura úmida e idade de carregamento de 7 dias. A fluência é modelada pela equação:

$$J(t, t_0) = \frac{1}{E_{cmto}} + \frac{\phi(t, t_0)}{E_{cmto}} \quad (91)$$

Onde:

E_{cmto} – É o módulo de elasticidade no instante de carregamento (MPa ou psi);

$$E_{cmto} = 0,043 \cdot \gamma^{1,5} \cdot \sqrt{f_{cmto}} \quad (92)$$

$\phi(t, t_0)$ – É o coeficiente de fluência, modelado por:

$$\phi(t, t_0) = \frac{(t - t_0)^{0,6}}{10 + (t - t_0)^{0,6}} \phi(\infty, t_0) \quad (93)$$

$(t - t_0)$ – Período de tempo desde a aplicação da carga (dias);

$\phi(\infty, t_0)$ – Coeficiente de fluência em $t = \infty$;

$$\phi(\infty, t_0) = 2,35 \gamma_c \quad (94)$$

$$\gamma_c = \gamma_{1a} \cdot \gamma_s \cdot \gamma_\psi \cdot \gamma_{ar} \cdot \gamma_U \cdot \gamma_h \text{ ou } \gamma_{vs} \quad (95)$$

Para idades de carregamento maiores que 7 dias e cura úmida do concreto, tem-se:

$$\gamma_{1a} = 1,25 t_0^{-0,118} \quad (96)$$

Para concreto curado a vapor, tem-se:

$$\gamma_{1a} = 1,13 t_0^{-0,094} \quad (97)$$

Os coeficientes γ_s , γ_ψ e γ_{ar} são todos relacionados à composição do concreto e calculados por:

$$\gamma_s = 0,82 + 0,00264s \quad (98)$$

$$\gamma_\psi = 0,88 + 0,0024\Psi \quad (99)$$

$$\gamma_{ar}=0,46+0,09ar \quad (100)$$

$$\gamma_U=1,27-0,67U; \quad U \geq 0,40 \quad (101)$$

Onde:

s – Consistência do concreto pelo abatimento do tronco de cone (mm);

Ψ – Proporção de agregado miúdo no total de agregado em percentagem de massa;

ar – Teor de ar (%);

U – Umidade relativa do ambiente;

O coeficiente de espessura da peça (γ_h) pode ser calculado por dois métodos:

- I. Método da espessura média, que deve estar entre 150mm e 380mm, é calculado por:

$$\gamma_h=1,14-0,023h, \text{ para } (t-t_0) < 1 \text{ ano} \quad (102)$$

$$\gamma_h=1,10-0,017h, \text{ para } (t-t_0) > 1 \text{ ano} \quad (103)$$

h – espessura média (mm)

- II. Método da relação volume superfície, calculado por:

$$\gamma_{vs} = \frac{2}{3} \left[1 + 1,13 e^{-0,0213(V/S)} \right] \quad (104)$$

V/S – Relação volume superfície (mm);

A deformação por retração após 7 dias para cura úmida é definida por:

$$\varepsilon_{cs}(t, t_s) = \frac{t}{35+t} \cdot \varepsilon_{cs}(\infty, t_s) \quad (105)$$

$$\varepsilon_{cs}(\infty, t_s) = 780 \gamma_{sh} \cdot 10^{-6} \quad (106)$$

t – Idade do concreto após início da secagem (dias);

t_s – Idade do concreto no início da secagem (dias);

$\varepsilon_{cs}(\infty, t_s)$ – Deformação por retração última;

γ_{sh} – Fatores de correção para condições fora do padrão, dados por:

$$\gamma_{sh} = \gamma_U \cdot \gamma_s \cdot \gamma_\Psi \cdot \gamma_c \cdot \gamma_{cr} \cdot \gamma_h \text{ ou } \gamma_{vs} \quad (107)$$

Para cura úmida num período diferente de 7 dias, utiliza-se (γ_{cp}) dado pela TABELA 37.

TABELA 37 - FATOR DE CORREÇÃO REFERENTE AO PERÍODO DE CURA INICIAL ÚMIDA

Duração da cura úmida	Coefficiente γ_{cp}
1	1,2
3	1,1
7	1,0
14	0,93
28	0,86
90	0,75

FONTE: ACI (2008)

8.4 MODELO GARDNER E LOCKMAN (2001) – GL2000

O modelo GL2000 foi proposto restrito a tensões da ordem de 40% da resistência média à compressão. De acordo com Gardner e Lockman (2001), o método pode ser usado independentemente dos agregados que estão no concreto, temperatura de vazamento ou regime de cura. Os valores previstos podem ser melhorados medindo o desenvolvimento da resistência do concreto com o tempo e o módulo de elasticidade. Pelo modelo GL2000, a função de fluência $J(t, t_0)$ é aproximada por:

$$J(t, t_0) = \frac{1}{E_{cm t_0}} + \frac{\phi_{28}(t, t_0)}{E_{cm 28}} \quad (108)$$

Na equação (108), a tensão elástica é o inverso do módulo de elasticidade $E_{cm t_0}$ na idade do carregamento, e a fluência básica é razão entre o coeficiente de fluência aos 28 dias $\phi_{28}(t, t_0)$ pelo módulo de elasticidade aos 28 dias $E_{cm 28}$.

O coeficiente de fluência $\phi_{28}(t, t_0)$ é a proporção da tensão de fluência pela tensão elástica devido à carga aplicada aos 28 dias, aproximado por:

$$\phi_{28}(t, t_0) = \Phi(t_c) \left[2 \left(\frac{(t-t_0)^{0,3}}{(t-t_0)^{0,3} + 14} \right) + \sqrt{\frac{7}{t_0} \cdot \frac{t-t_0}{t-t_0+7}} + 2,5(1-1,086h^2) \left(\frac{t-t_0}{t-t_0+0,15(V/S)^2} \right) \right] \quad (109)$$

$$\Phi(t_c) = \left[1 - \left(\frac{t-t_c}{t-t_c+0,12(V/S)^2} \right) \right] \quad (110)$$

$\Phi(t_c)$ – Coeficiente de correção que considera a secagem antes do carregamento;

t – Idade do concreto no instante considerado (dias);

t_0 – Idade do concreto quando carregado (dias);

t_c – Idade do concreto no início do processo de secagem (dias);

h – Umidade relativa do ambiente (decimal);

V/S – Relação entre volume e área de superfície (mm).

A deformação por retração, pelo modelo GL2000, é definida por:

$$\varepsilon_{sh}(t-t_c) = \varepsilon_{shu} \beta(h) \beta(t-t_c) \quad (111)$$

$$\varepsilon_{shu} = 900K \left(\frac{30}{f_{cm28}} \right)^{1/2} 10^{-6} \quad (112)$$

$$\beta(h) = 1 - 1,18h^4 \quad (113)$$

$$\beta(t-t_c) = \left(\frac{t-t_c}{t-t_0+0,12(V/S)^2} \right)^{1/2} \quad (114)$$

$$f_{cmi} = \left(e^{\frac{s}{2} \left(1 - \sqrt{\frac{28}{t}} \right)} \right)^2 f_{cm28} \quad (115)$$

$$f_{cm28} = 1,1 f_{ck28} + 5 \quad (116)$$

$$E_{cm} = 3500 + 4300 \sqrt{f_{cmi}} \quad (117)$$

$\beta(h)$ – Coeficiente de correção do efeito da umidade relativa do ambiente na retração;

ε_{su} – Deformação por retração;

K – Coeficiente que depende do tipo de cimento dado por:

1,0 para cimento tipo I;

0,75 para cimento tipo II;

1,15 para cimento tipo III;

f_{cm28} – Resistência média à compressão aos 28 dias (MPa)

f_{cmt} – Resistência à compressão média, na idade t dias (MPa)

f_{ck28} – Resistência característica à compressão aos 28 dias (MPa);

E_{cm} – Módulo de elasticidade (MPa) do concreto na idade t (dias);

s – Coeficiente que depende do tipo de cimento, dado por:

0,335 para cimento tipo I;

0,4 para cimento tipo II;

0,13 para cimento tipo III;

8.5 MODELO NBR6118 (2004)

No Brasil há uma norma técnica, NBR6118, publicada pela Associação Brasileira de Normas Técnicas – ABNT, como um modelo de referência para aproximar a curva de fluência (ABNT, 2004). Neste trabalho será utilizada a NBR6118 de 2004, que considera a deformação total por fluência do concreto (ε_{cc}) composta de duas partes, equação (118): fluência rápida e fluência lenta.

$$\varepsilon_{cc} = \varepsilon_{cca} + \varepsilon_{ccf} + \varepsilon_{ccd} \quad (118)$$

A fluência rápida (ε_{cca}) é dita irreversível e seu efeito é significativo nas primeiras vinte quatro horas após a aplicação da carga de origem. A fluência lenta é subdividida em duas partes: fluência lenta e irreversível (ε_{ccf}) e a outra é fluência lenta reversível (ε_{ccd}). Assim, a deformação total por fluência ($\varepsilon_{c,total}$) e seu respectivo coeficiente de fluência (φ) são aproximados pelas equações (119) e (120).


$$\varepsilon_{c,total} = \varepsilon_c + \varepsilon_{cc} = \varepsilon_c(1 + \varphi) \quad (119)$$

$$\varphi = \varphi_a + \varphi_f + \varphi_d \quad (120)$$

φ_a – Coeficiente de fluência rápida; φ_f – Coeficiente de fluência lenta irreversível e φ_d – Coeficiente de fluência lenta reversível.

Este modelo apresenta algumas hipóteses de simplificação no cálculo dos efeitos da fluência para concreto submetido às tensões de serviço. A seguir estão as hipóteses consideradas:

- A deformação por fluência (ε_{cc}) varia linearmente com a tensão aplicada;
- Para acréscimos de tensão aplicados em instantes diferentes, os respectivos efeitos de fluência se superpõem;
- A fluência rápida produz deformações constantes ao longo do tempo;
- Os valores do coeficiente (φ_a) são função da relação entre a resistência do concreto no momento da aplicação da carga e sua resistência final;
- O coeficiente de deformação lenta reversível (φ_d) depende apenas da duração do carregamento; o seu valor final e o seu desenvolvimento ao longo do tempo são independentes da idade do concreto no momento da aplicação da carga;
- O coeficiente de deformação lenta irreversível (φ_f) é dependente: da umidade relativa do ambiente (U), da consistência do concreto no lançamento (abatimento), da espessura fictícia da peça (h_{fc}), da idade fictícia do concreto no instante (t_0) da aplicação da carga e da idade fictícia do concreto no instante considerado (t);
- Para o mesmo concreto, as curvas de deformação lenta irreversível em função do tempo, correspondentes a diferentes idades do concreto no instante do carregamento, são obtidas, umas em relação às outras, por deslocamento paralelo ao eixo das deformações, conforme a FIGURA 57:



Fonte: NBR6118 (2004)

A deformação por fluência, instante t , é modelada por:

$$\varepsilon_{cc}(t, t_0) = \varepsilon_{cca} + \varepsilon_{ccd} + \varepsilon_{ccf} = \frac{\sigma_c}{E_{cs28}} \cdot \varphi(t, t_0) \quad (121)$$

$$E_{cs28} = 0,85 \cdot 5600 \sqrt{f_{ck}} \quad (122)$$

$$\varphi(t, t_0) = \varphi_a + \varphi_{f\infty} [\beta_f(t) - \beta_f(t_0)] + \varphi_{d\infty} \beta_d \quad (123)$$

$$\varphi_a = 0,8 \left(1 - \frac{f_c(t_0)}{f_c(t_\infty)} \right) \quad (124)$$

t – idade fictícia do concreto no instante considerado (dias);

t_0 – idade fictícia do concreto no instante do carregamento (dias);

$\frac{f_c(t_0)}{f_c(t_\infty)}$ – Função de crescimento da resistência do concreto no tempo, dada por:

$$\frac{f_c(t_0)}{f_c(t_\infty)} = e^{\alpha \left(1 - \sqrt{\frac{28}{t}} \right)} \quad (125)$$

α - Coeficiente que depende do tipo de cimento, dado por:

0,38 para concreto de cimento Portland (CP III e IV);

0,25 para concreto cimento Portland (CP I e II);

0,20 para concreto cimento Portland (CP V-ARI);

$\varphi_{f\infty} = \varphi_{lc} \cdot \varphi_{2c}$ – É o coeficiente de deformação lenta irreversível;

φ_{1c} – Coeficiente dependente da umidade relativa do ambiente U , em %, e da consistência do concreto, conforme a TABELA 38.

TABELA 38 - VALORES USUAIS PARA DETERMINAÇÃO DA FLUÊNCIA E DA RETRAÇÃO

Ambiente	Umidade U %	Fluência $\varphi_{1c}^{1) 3)}$			Retração $10^4 \varepsilon_{1s}^{2) 3)}$			$\gamma^{4)}$	
		Abatimento de acordo com a ABNT NBR NM67							
		cm							
		0 - 4	5 - 9	10 - 15	0 - 4	5 - 9	10 - 15		
Na água	-	0,6	0,8	1,0	+ 1,0	+ 1,0	+ 1,0	30,0	
Muito úmido imediatamente acima da água	90	1,0	1,3	1,6	- 1,0	-1,3	-1,6	5,0	
Ao ar livre, em geral	70	1,5	2,0	2,5	- 2,5	- 3,2	- 4,0	1,5	
Em ambiente seco	40	2,3	3,0	3,8	- 4,0	- 5,2	- 6,5	1,0	

¹⁾ $\varphi_{1c} = 4,45 - 0,035U$ para abatimento no intervalo de 5 cm a 9 cm e $U \leq 90\%$.

²⁾ $10^4 \varepsilon_{1s} = -6,16 - (U/484) + (U^2/1590)$ para abatimentos de 3 cm a 9 cm e $U \leq 90\%$.

³⁾ Os valores de φ_{1c} e ε_{1s} para $U \leq 90\%$ e abatimento entre 0 cm e 4 cm são 25% menores e para abatimentos entre 10 cm e 15 cm são 25% maiores.

⁴⁾ $\gamma = 1 + \exp(-7,8 + 0,1 U)$ para $U \leq 90\%$

Notas

1 - Para efeito de cálculo, as mesmas expressões e os mesmos valores numéricos podem ser empregados no caso de tração.

2 - Para o cálculo dos valores de fluência e retração, a consistência do concreto é aquela correspondente à obtida com o mesmo traço sem a adição de superplastificantes e superfluidificantes.

FONTE: NBR6118 (2004)

φ_{2c} – Coeficiente que depende da espessura fictícia h_{fic} da peça, definida por:

$$\varphi_{2c} = \frac{42 + h_{fic}}{20 + h_{fic}} \quad (126)$$

$\beta_f(t)$ ou $\beta_f(t_0)$ – Coeficiente relativo à deformação lenta irreversível em função da idade do concreto dado por:

$$\beta_f(t) = \frac{t^2 + At + B}{t^2 + Ct + D} \quad (127)$$

Onde:

$$A = 42h^3 - 350h^2 + 588h + 113$$


$$B = 768h^3 - 3060h^2 + 3234h - 23$$

$$C = -200h^3 + 13h^2 + 1090h + 183$$

$$D = 7579h^3 - 31916h^2 + 35343h + 1931$$

h – Espessura fictícia, em metros, conforme FIGURA 58; para valores fora do intervalo $(0,05 \leq h \leq 1,6)$, adota-se os extremos correspondentes;

FIGURA 58 - VARIAÇÃO DE $\beta_f(t)$ EM RELAÇÃO À IDADE FICTÍCIA DO CONCRETO



Idade fictícia do concreto em dias

FONTE: NBR6118 (2004)

$\varphi_{doo} = 0,4$ – Valor final do coeficiente de deformação lenta reversível que é considerado;

β_d – Coeficiente relativo à deformação lenta reversível em função do tempo em $[t_0, t]$ decorrido após o carregamento, definido por:

$$\beta_d = \frac{t - t_0 + 20}{t - t_0 + 70} \quad (128)$$

Conforme a NBR6118, o valor da retração do concreto depende da:

- i) Umidade relativa do ambiente;
- ii) Consistência do concreto no lançamento;
- iii) Espessura fictícia da peça.

Assim, a deformação devido à retração, no intervalo $[t_0, t]$, pode ser modelada por:

$$\varepsilon_{cs}(t, t_0) = \varepsilon_{cs\infty}(\infty, t_s) \cdot [\beta_s(t) - \beta_s(t_0)] \quad (129)$$

$$\varepsilon_{cs\infty}(\infty, t_s) = \varepsilon_{1s} \cdot \varepsilon_{2s} \quad (130)$$

$$\varepsilon_{2s} = \frac{33 + 2h_{fic}}{20,8 + 3h_{fic}} \quad (131)$$

$\varepsilon_{cs\infty}(\infty, t_0)$ – Deformação por retração última;

ε_{1s} – Coeficiente dependente a umidade relativa do ambiente e da consistência do concreto apresentado na TABELA 38;

ε_{2s} – Coeficientes que dependem da espessura fictícia (h_{fic}) da peça de concreto.

h_{fic} – Espessura fictícia do concreto dada por:

$$h_{fic} = \gamma \cdot \frac{2 \cdot A_c}{u} \quad (132)$$

A_c – Área da secção transversal da peça;

u – Perímetro externo da secção transversal em contato com o ar.

Destaca-se que a espessura fictícia do concreto é utilizada nos modelos de predição de fluência e retração com unidades diferentes para a determinação dos parâmetros: φ_{2c} – em centímetros, $\beta_r(t)$ – em metros e ε_{2s} – em centímetros.

γ - Coeficiente dependente da umidade relativa do ambiente, conforme TABELA 38.

$\beta_s(t)$ ou $\beta_s(t_0)$ – Coeficiente relativo à retração, nos instantes t ou t_0 definido pela equação (133) e mostrado na FIGURA 59.

$$\beta_s(t) = \frac{\left(\frac{t}{100}\right)^3 + A\left(\frac{t}{100}\right)^2 + B\left(\frac{t}{100}\right)}{\left(\frac{t}{100}\right)^3 + C\left(\frac{t}{100}\right)^2 + D\left(\frac{t}{100}\right) + E} \quad (133)$$

Onde:


$$A = 40$$

$$B = 116h^3 - 282h^2 + 220h - 4,8$$

$$C = 2,5h^3 - 8,8h^2 + 40,7$$

$$D = -75h^3 + 585h^2 + 496h - 6,8$$

$$E = -169^4 + 88h^3 + 584h^2 - 39h + 0,8$$



FONTE: NBR6118 (2004)

t – A idade fictícia do concreto é aproximada por:

$$t = \alpha \sum_i \frac{T_i + 10}{30} \cdot \Delta t_{ef,i} \quad (134)$$

α - Coeficiente dependente da velocidade de endurecimento do concreto, conforme TABELA 39.

TABELA 39 - VALORES DA FLUÊNCIA E DA RETRAÇÃO POR SECAGEM EM FUNÇÃO DA VELOCIDADE DO ENDURECIMENTO DO CONCRETO

Cimento Portland (CP)	α	
	Fluência	Retração
De endurecimento lento (CP III E CP IV, todas as classes de resistência)	1	1
De endurecimento normal (CP I e CP II, todas as classes de resistência)	2	
De endurecimento rápido (CP V-ARI)	3	

Onde:

CP I e CP I-S – Cimento Portland comum;

CP II-E, CP II-F e CP II-Z – Cimento Portland composto;

CP III – Cimento Portland de alto-forno;

CP IV – Cimento Portland pozolânico;

CP V-ARI – Cimento Portland de alta resistência inicial;

RS – Cimento Portland resistente a sulfatos (propriedade específica de alguns dos tipos de cimento citados)

FONTE: NBR6118 (2004)

A NBR6118 também fornece valores médios finais, como referência, dos coeficientes de fluência e retração, mostrados na TABELA 40.

TABELA 40 - VALORES CARACTERÍSTICOS DA DEFORMAÇÃO ESPECÍFICA $\varepsilon_{cs}(\infty, t_0)$ E O COEFICIENTE DE FLUÊNCIA $\varphi(\infty, t_0)$

Umidade Ambiente (%)		40		55		75		90		
Espessura Fictícia (2A _c / u)		20	60	20	60	20	60	20	60	
φ(t _∞ , t ₀)	t ₀	5	4,4	3,9	3,8	3,3	3,0	2,6	1,3	2,1
		30	3,0	2,9	2,6	2,5	2,0	2,0	1,6	1,6
		60	3,0	2,6	2,2	2,2	1,7	1,8	1,4	1,4
ε _{cs}	dias	5	-0,44	-0,39	-0,37	-0,33	-0,23	-0,21	-0,10	-0,09
(t _∞ , t ₀)		30	-0,37	-0,38	-0,31	-0,31	-0,20	-0,20	-0,09	-0,09
‰		60	-0,32	-0,36	-0,27	-0,30	-0,17	-0,19	-0,08	-0,09

FONTE: NBR6118 (2004)

Nas pesquisas recentes sobre fluência e retração do concreto os modelos desenvolvidos enfatizam características como viscoelasticidade do concreto, especialmente para as primeiras idades do concreto. Han et al. (2017) apresentaram um modelo considerando a não linearidade da fluência e a teoria da viscoelasticidade, para as primeiras idades do concreto, propondo uma modificação para o modelo B3. Delsaute et al. (2017) desenvolveram um modelo de atualização

do Model Code 2010 para a curva de fluência, com ênfase para as primeiras idades do concreto, destacando dois testes diferentes de carregamento. O teste clássico de carregamento (em 6 dias) e um teste de carregamento em minutos (a cada 5 minutos).

Awruch e Gomes (2014) apresentaram uma metodologia sobre a análise de confiabilidade estrutural de concreto armado considerando a inclusão de efeitos estocásticos de propriedade dos materiais em que foi utilizado o Método de Elementos Finitos (MEF) para a representação do comportamento do concreto armado para carga de curta e longa duração.